



Sveučilište u Zagrebu

Filozofski fakultet

Nataša Rogulja

RAZVOJ MULTIMEDIJSKE INSTRUKTIVNE PORUKE ZA PROGRAMSKI JEZIK LOGO

DOKTORSKI RAD

Zagreb, 2018.



Sveučilište u Zagrebu

Filozofski fakultet

Nataša Rogulja

RAZVOJ MULTIMEDIJSKE INSTRUKTIVNE PORUKE ZA PROGRAMSKI JEZIK LOGO

DOKTORSKI RAD

Mentori:

izv. prof. dr. sc. Tomislava Lauc

prof. dr. sc. Ljubica Bakić-Tomić

Zagreb, 2018.



Sveučilište u Zagrebu

Faculty of Humanities and Social Sciences

Nataša Rogulja

THE DEVELOPMENT OF MULTIMEDIA INSTRUCTIONAL MESSAGE FOR THE PROGRAMMING LANGUAGE LOGO

DOCTORAL THESIS

Supervisors:

PhD. Tomislava Lauc, associate professor

PhD. Ljubica Bakić-Tomić, full professor

Zagreb, 2018

ZAHVALE

*Rad posvećujem Tebi,
...koji si Utjelovljenje Ljubavi i čija su Energija, Znanje i Podrška pronašli put do mene
kroz mnoge duše za vrijeme pisanja ovog rada.
...hvala Ljubici, Tomislavi, Jadranki, Anki, Haranu, Severinu, Julijani, Miroslavu,
Zdenki, Heleni, Ivani, Ani, Giovanni, Olgici.
...hvala Majci, Ocu i Bratu.
...hvala diksha Guru, Gangi i svim Siksha Guruima (znate tko ste).
...i na kraju, hvala studentima, glavnim akterima ovog rada.*

INFORMACIJE O MENTORIMA

Izv. prof. dr. sc. Tomislava Lauc zaposlena je na Katedri za organizaciju znanja, Odsjeka za informacijske i komunikacijske znanosti Filozofskog fakulteta Sveučilišta u Zagrebu. Njeno područje interesa je multimedijски instrukcijski dizajn. Nositeljica je nekoliko kolegija na preddiplomskom, diplomskom i poslijediplomskom studiju Odsjeka za informacijske i komunikacijske znanosti. Bila je mentorica u više obranjenih diplomskih i doktorskih radova. Suradivala je u nizu znanstvenih projekata. Autorica je više poglavlja u knjigama, kao i znanstvenih radova.

Prof. dr. sc. Ljubica Bakić-Tomić zaposlena je na Sveučilištu Sjever u Varaždinu, gdje trenutno obnaša dužnost pročelnice odjela za Komunikologiju i odnose s javnostima i vodi sveučilišni diplomski studij Odnosa s javnostima. Kao sveučilišni nastavnik radila je na Učiteljskom fakultetu Sveučilišta u Zagrebu. Sudjelovala je u izvođenju dva doktorska studija „Rani odgoj i obvezno obrazovanje“, na Učiteljskom fakultetu Sveučilišta u Zagrebu i dokorskog studija Informacijskih i komunikacijskih znanosti, Filozofskog fakulteta u Zagrebu. Izradila je u suautorstvu nastavnu skriptu *Odabrana poglavlja iz metodike nastave informatike*, za nastavnu literaturu kolegija metodike u informatici na Učiteljskom fakultetu Sveučilišta u Zagrebu. Bila je suorganizator više međunarodnih znanstvenih skupova. Objavila je 4 knjige (od toga dvije u inozemstvu), brojne zbornike u suautorstvu, te 63 znanstvena i stručna rada.

SAŽETAK

Naslov ove doktorske disertacije je *Razvoj multimedijske instruktivne poruke za programski jezik Logo*. Programski jezik Logo je viši programski jezik treće generacije autora Seymour Paperta, Wally Feurzeiga i Danny Bobrowa, razvijen 1966. godine (Papert, S., 1983). Konstruktivistička priroda Logo jezika ukorijenjena je u kognitivnoj teoriji učenja, a temelji se na načelu „kornjače“ odnosno pomoćnog objekta u formi grafičkog pokazivača za obavljanje osnovnih operacija kretanja definiranih parametrima programskih naredbi. Većina istraživanja Logo jezika u svijetu bila je usmjerena na razvoj kognitivnih sposobnosti kod učenika mlađeg školskog uzrasta. Malo je istraživanja provedeno sa studentima (Lee, M. O. C., 1991; Fay, A. L. i Mayer, R. E., 1994), a još manje s budućim učiteljima informatike.

Cilj ovom istraživanju bio je ispitati učinkovitost *multimedijske instruktivne poruke za programski jezik Logo* (MIPL), kod studenata razredne nastave, budućih učitelja informatike. Radi ispitivanja razlika u zapamćivanju i razumijevanju sadržaja, razvijen je obrazovni sadržaj sačinjen od osnovnih pojmova iz 9 odabranih nastavnih tema programskog jezika Logo, u formi multimedijske instruktivne poruke utemeljene na osam osnovnih načela (*načelo multimedija, načelo prostorne povezanosti, načelo vremenske usklađenosti, načelo koherentnosti, načelo modaliteta, načelo zalihosnosti, načelo individualnih razlika, načelo signalizacije*) i jednim naprednim načelom (*načelo animacije i interaktivnosti*) *kognitivne teorije multimedijskog usvajanja znanja* (kontrolna skupina), te s nadopunjenim načelom raščlanjivanja *modela kognitivnog procesa multimodalnog razumijevanja* (eksperimentalna skupina). U istraživanju su sudjelovali studenti treće, četvrte i pete godine Učiteljskog fakulteta Sveučilišta u Zagrebu. Istraživanje je provedeno na ciljanom uzorku od 98 ispitanika razredne nastave, modula informatike, u Zagrebu (45) i Čakovcu (53). Kontrolna skupina brojala je 48 ispitanika, a eksperimentalna 50 ispitanika. U provedenom istraživanju primijenjena je metoda eksperimenta s paralelnim grupama. Eksperimentalni program trajao je četiri tjedna u zimskom semestru 2015./2016. akademske godine, što je obuhvaćalo inicijalni susret voditelja programa i ispitanika radi provođenja predtesta za dobivanje osnovnih informacija o ispitanicima, te tri tjedna provođenja eksperimentalnog programa. Sveukupni angažman studenata tijekom četiri tjedna istraživanja iznosio je 160 minuta.

U sva tri tjedna istraživanja nisu pronađene statistički značajne razlike između kontrolne i eksperimentalne skupine ispitanika u pogledu rješavanja zadataka zapamćivanja i razumijevanja sadržaja čime nije potvrđena prva hipoteza (H1). Rezultati istraživanja pokazali su da dodatno primijenjeno načelo raščlanjivanja nije pridonijelo boljem zapamćivanju i

razumijevanju sadržaja multimedijske instruktivne poruke, za geometrijsku (prvi i drugi tjedan) i negeometrijsku (treći tjedan) izlaznu vrijednost podataka, čime nisu potvrđene druga (H2) i treća (H3) hipoteza. Mogući univerzalni razlozi mogu se pronaći u problemima s kojima se studenti susreću u procesu programiranja, a koji su se pojavili i u ovom istraživanju: niska razina matematičkog i logičkog predznanja (Byrne, P. i Lyons, G., 2001; Caspersen, M. E., 2007), te sposobnost logičkog razmišljanja i razvoj održivih mentalnih modela (Bergin, S. i Reilly, R., 2006, prema Caspersen, M. E., 2007, str. 56-58).

Ispitanici su predvidjeli upravo ono što su brojni istraživači potvrdili, da je stupanj aktivnog angažmana korisnika u susretu sa vizualnim sadržajem važniji od načina prikaza sadržaja ili reprezentacijskog aspekta vizualizacije (Naps, T. L. i sur., 2002; Rapp, D. N., 2005; de Koning B. B. i sur., 2011). Budući da je učinkovitost primjene vizualizacije povezana sa stupnjem kognitivnog angažmana u procese relevantne za smisleno usvajanje znanja (Mayer, R. E., 2008), postoji mogućnost da bi se nadogradnjom načela raščlanjivanja sa cjelovitim animacijskim načelima fleksibilnosti i interakcije unaprijedio proces učenja, bez obzira na nisku razinu geometrijskog predznanja ispitanika. Rezultati provedenog istraživanja (nepotvrđene hipoteze istraživanja) sugeriraju da je u budućim istraživanjima važno provjeriti predznanje ispitanika, jer je u ovom istraživanju predviđena očekivana razina znanja geometrije i razvijenosti prostornih sposobnosti, što kod ispitanika nije bio slučaj.

Znanstveni doprinos doktorskoga rada sastoji se u oblikovanju i razvoju *multimedijske instruktivne poruke za programski jezik Logo* (MIPL), za buduće učitelje informatike, koja objedinjuje kognitivni i programersko-metodički aspekt. Ovo je prvi rad koji prikazuje razvoj i primjenu *multimedijske instruktivne poruke* kao kognitivno pomoćno sredstvo za usvajanje osnovnih pojmova programskog jezika Logo, utemeljene na empirijski utvrđenim načelima *kognitivne teorije multimedijskog usvajanja znanja* (engl. *cognitive theory of multimedia learning*), (Mayer, R. E., 2001, 2005, 2014a) i dodatnom *načelu raščlanjivanja* iz područja algoritama i strukture podataka, definiranom prema *modelu kognitivnog procesa multimodalnog razumijevanja* (engl. *cognitive process model of multimodal comprehension*) (Narayanan, N. H. i Hegarty, M., 2002). Programersko-metodički aspekt MIPL-a služi samorefleksiji budućih učitelja u njihovom logičkom, matematičkom i informatičkom znanju za teme koje će provoditi u nastavi informatike.

Ključne riječi: programski jezik Logo, „kornjačina geometrija“, proceduralno programiranje, *kognitivna teorija multimedijskog usvajanja znanja*, multimedijska instruktivna poruka, instrukcijski dizajn, *model kognitivnog procesa multimodalnog*

razumijevanja, načelo raščlanjivanja, *teorija kognitivnog opterećenja*, esencijalno, sadržajno irelevantno i sadržajno relevantno kognitivno opterećenje.

ABSTRACT

The title of this dissertation is *Development of multimedia instructional message for the Logo programming language*. Logo is a high-level programming language of third generation created in 1966 by the authors Seymour Papert, Wally Feurzeig and Danny Bobrow (Papert, S., 1983). The constructivist nature of the Logo language stems from the cognitive learning theory and is based on the 'turtle' principle, i.e. on the auxiliary object in the shape of a graphic pointer which manages basic movement operations as defined by the parameters of programming commands. Most studies of the Logo language focused on the development of cognitive abilities among younger pupils. Few studies were focused on university students (Lee, M. O. C., 1991; Fay, A. L. & Mayer, R. E., 1994) and even fewer on future computer science teachers.

The aim of this research was to examine the effectiveness of the *multimedia instructional message for the Logo programming language (MIPL)* among future elementary school teachers (specifically majoring in computer science). For this purpose educational content was created, which included the basic concepts from nine selected teaching units in Logo programming. The content in the form of a multimedia instructional message was based on eight fundamental principles (*multimedia principle, spatial contiguity principle, temporal contiguity principle, coherence principle, modality principle, redundancy principle, individual differences principle and signaling principle*), one advanced principle (*animation and interactivity principle*) of the *Cognitive Theory of Multimedia Learning* (control group) and the broadened decomposition principle of the *Cognitive Process Model of Multimodal Comprehension* (experimental group). Retention and transfer tests were used in the study with the aim of examining the differences in students' retention and understanding of the educational content in the form of a multimedia instructional message.

The thesis examines the validity of the following three hypotheses:

(H1) When solving a set of objective type tasks, which examine content retention and comprehension, students using the multimedia instructional message with the application of the decomposition principle shall accomplish better results than those using the multimedia instructional message without this principle.

(H2) When the content output for a set of objective type tasks is geometrical type of data, students using the multimedia instructional message with the decomposition principle shall achieve better results in content retention and comprehension than students using the multimedia instructional message without the said principle.

(H3) When the content output for a set of objective type tasks is non-geometrical type of data, students using the multimedia instructional message with the decomposition principle shall achieve better results in content retention and comprehension than students using the multimedia instructional message without the said principle.

The subjects were third, fourth and fifth year students studying at the Faculty of Teacher Education of the University of Zagreb. Research was conducted on a non-random sample consisting of 98 students, future elementary school teachers majoring in computer science, with 45 subjects in Zagreb and 53 in Čakovec. The control group consisted of 48 and the experimental group of 50 subjects. Within the scope of the research the experimental method with parallel group was applied. The experimental program ran throughout the course of four weeks in the winter semester of 2015/2016. In the first week the initial lesson took place, during which the pre-test was administered with the aim of gathering basic information about the subjects. This was followed by three weeks of experimental program. The overall participation of the students throughout the four weeks amounted to 160 minutes.

During the course of the three weeks no statistically significant differences between the control and the experimental group were found with regard to retention and transfer tests, so that the first hypothesis (H1) was not corroborated. The additionally applied decomposition principle did not contribute to improved retention and transfer of the content of the *multimedia instructional message* in relation to both the geometrical (first and second week) and non-geometrical (third week) data output, leading to the rejection of the second (H2) and the third (H3) hypothesis. During the first two weeks of the study fifth-year students accomplished a lower score than third- and fourth-year students in content retention tasks. There were no statistically significant differences between third- and fourth-year students in this respect. It can be concluded that the level of prior knowledge in mathematics and logic pertaining to geometric angles, shapes (parallelogram, rhombus) and planes (cube) among third- and fourth-year students in the survey was greater than that of fifth-year students. Limited prior knowledge made the process of cognitive association between program command parameters (moves and rotation angles) and corresponding visual representations of the turtle's movement difficult, resulting in an inability to follow the program presentation, as well as program reading and writing. In order to be able to follow the program presentation in the form of mental simulation (Sorva, J., 2012), one needed a certain level of prior knowledge in geometry, which would lead to the generation of a mental model of the program concept (commands and structures) presented. However, it is assumed that instead of investing most of their cognitive capacities into program concepts, the subjects used them to grasp the

geometry content section. For this reason it was not possible to adequately examine the effect of the decomposition principle on content retention and comprehension, i.e. to examine the acquired programming skills. In addition, the decomposition principle, which was applied to the programming section of the content in the experiment group, may have been an adverse factor in the learning process as it presented an additional essential cognitive load for the students' working memory. This is confirmed by the subjects' reports of self-estimated high mental effort. In the third week of the study a very low level of task-solving success and a very high level of self-estimated mental effort were observed in all subjects in both the control and the experimental group. This is attributed to limited prior knowledge in logic (abstract content of the message), unsuccessful generation of mental models in the first two tasks or the use of pre-existing non-viable mental models of program concepts acquired in previous education and built on misconceptions. As confirmed by other studies, this resulted in difficulties with following the program presentation (Kaczmarczyk, L. C. et al., 2010, Simon, 2011), inaccurate reading of the program and writing of unproductive and non-functional programs (Sorva, J., 2012).

In the third week of the survey MIPL content included the following programming concepts: variable, MAKE command for the association of numerical values or sets of sign variables, and program structures of WHILE and FOR loops. Given that these concepts are considered the most complex (Dehnadi, S. & Bornat, R., 2006; Kaczmarczyk, L. C. et al., 2010; Sorva, J., 2012), students possibly had non-viable or non-existent mental models from previous education.

As the subjects' prior knowledge in geometry and the level of developed spatial abilities did not match the expected level in this study, results (uncorroborated research hypotheses) suggest the importance of checking subjects' prior knowledge before conducting future studies. Possible general reasons for such results could be found in the problems students face in the programming process: insufficient mathematical and logical prior knowledge (Byrne, P. & Lyons, G., 2001; Caspersen, M. E., 2007), as well as logical thinking abilities and the development of viable mental models (Bergin, S. & Reilly, R., 2006, according to: Caspersen, M. E., 2007, pg. 56-58).

Subject responses to categorized questions showed that 91,8% of them never encountered this kind of multimedia content for the development of programming skills, and 70% of them reported they liked this way of learning how to program. According to control and experimental group participants, this way of learning is attractive because it is different, useful, new, motivating, interesting in its content and learning style, and is not boring or dry.

Students pointed out the elements of MIPL they found important: (1) digital way of presenting information as opposed to traditional presentation, for its visual and aural demonstration accompanied by speech; (2) possibility of setting one's own learning pace owing to content interactivity; (3) content structure with examples in the order of complexity from simple to more complex, i.e. *a gradual, step-by-step teaching approach*; (4) detailed analysis of each procedure and task; (5) *possibility to visualize and memorize information more easily*; (6) an overview of theoretical part of the content supported by additional explanations in speech and specific examples with a simultaneous display of results; (7) possibility of self-assessment through independent task-solving; (8) enough time at disposal for new concept acquisition; (9) coherence of content and ease of visual perception; (10) ease of content access, support to traditional teaching and the possibility of applying the content beyond the classroom activities.

According to responses of subjects from both the control and the experimental group, the content of MIPL can be improved by the following: (1) clearer and more detailed instructions with an addition of more textual definitions and content during task explanation to prevent vagueness of subject matter; (2) additional programming tasks, short tests and practice examples during the learning process, accompanied by feedback; (3) additional visuals and animations to facilitate the visualization and turtle movement (control group) and emphasize the spoken elements (experimental group); (4) introduction of explanatory videos for concepts with a *step-by-step* approach; (5) introduction of teacher oral presentations to facilitate student comprehension of the task-solving principle.

The subjects confirmed the conclusions of numerous previous studies, namely that the degree of their active participation when dealing with visual content is more important than the content presentation method or the representational aspect of visualization (Naps, T. L. et al., 2002; Rapp, D. N., 2005; de Koning, B. B. et al., 2011). Given that the effectiveness of visual cues depends on the level of cognitive effort invested in the processes relevant to meaningful knowledge acquisition (Mayer, R. E., 2008), adding the complete animation principles of flexibility and interactivity to the decomposition principle might improve the learning process even with students' limited prior knowledge of geometry. In line with previous studies (Rias, R. M. & Zaman, H. B., 2013), the majority of subjects in both groups reported that all the visual and verbal advantages of multimedia content could not replace oral presentation and guidance by the teacher.

Scientific contribution of this thesis is the creation and development of the *multimedia instructional message for the Logo programming language* for future computer science

teachers, which brings together the cognitive and the programming-didactical aspect. This is the first thesis which presents the development and application of the *multimedia instructional message* as an auxiliary cognitive tool for learning the basic concepts of Logo programming language, based on empirically confirmed principles of the *Cognitive Theory of Multimedia Learning* (Mayer, R. E., 2001, 2005, 2014a), as well as the additional *decomposition principle* from the field of algorithms and data structures, defined according to the model of *Cognitive Process Model of Multimodal Comprehension* (Narayanan, N. H. & Hegarty, M., 2002). The aspect of the multimedia instructional message for the Logo programming language pertaining to programming methodology can serve as a self-assessment tool for future teachers when testing their knowledge of logic, mathematics and computer science for the topics they will be covering in their teaching.

Keywords: Logo programming language, *turtle* geometry, procedural programming, cognitive theory of multimedia learning, multimedia instructional message, instructional design, cognitive process model of multimodal comprehension, decomposition principle, cognitive load theory, extraneous, essential and generative processing.

SADRŽAJ

| | | |
|-------|---|-----|
| 1 | UVOD | 1 |
| 1.1 | Cilj i hipoteze istraživanja | 3 |
| 1.2 | Doprinos istraživanja..... | 4 |
| 1.3 | Pregled radnje..... | 5 |
| 2 | PREGLED LITERATURE | 7 |
| 2.1 | Programski jezik Logo | 7 |
| 2.1.1 | Povijesni razvoj Logo jezika | 7 |
| 2.1.2 | Karakteristike Logo jezika | 11 |
| 2.1.3 | Struktura Logo jezika | 14 |
| 2.1.4 | Istraživanja na području Logo jezika | 16 |
| 2.2 | Kognitivna teorija multimedijskog usvajanja znanja | 20 |
| 2.2.1 | Multimedijaska instruktivna poruka..... | 20 |
| 2.2.2 | Ljudski kognitivni sustav za obradu informacija | 21 |
| 2.2.3 | Memorijska struktura i kognitivni procesi..... | 24 |
| 2.2.4 | Mentalni modeli | 31 |
| 2.2.5 | Kognitivna opterećenja i instrukcijski dizajn | 38 |
| 2.2.6 | Obrada slika, govora i pisane riječi | 41 |
| 2.2.7 | Načela kognitivne teorije multimedijskog usvajanja znanja | 45 |
| 2.3 | Model kognitivnog procesa multimodalnog razumijevanja | 73 |
| 2.3.1 | Računalni algoritmi | 75 |
| 2.3.2 | Istraživanja | 76 |
| 3 | MULTIMEDIJSKA INSTRUKTIVNA PORUKA ZA PROGRAMSKI JEZIK LOGO | 78 |
| 3.1 | Struktura multimedijске instruktivne poruke za programski jezik LOGO..... | 78 |
| 3.2 | MIPL prve nastavne cjeline..... | 84 |
| 3.3 | MIPL druge nastavne cjeline..... | 100 |
| 3.4 | MIPL treće nastavne cjeline | 112 |
| 4 | METODOLOGIJA..... | 123 |
| 4.1 | Predmet istraživanja | 123 |
| 4.2 | Cilj i hipoteze istraživanja | 123 |
| 4.3 | Uzorak | 124 |
| 4.4 | Metoda istraživanja | 125 |
| 4.5 | Eksperimentalni program | 125 |
| 4.5.1 | Materijali i tehnička oprema..... | 125 |
| 4.5.2 | Varijable istraživanja..... | 127 |

| | | |
|-------|---|-----|
| 4.5.3 | Plan istraživanja | 127 |
| 5 | REZULTATI I DISKUSIJA | 130 |
| 5.1 | Analiza ispitanika | 130 |
| 5.2 | Ishodi učenja..... | 130 |
| 5.3 | Predtest | 132 |
| 5.4 | Analiza rezultata provedenog testiranja za prvi tjedan eksperimentalnog programa | 135 |
| 5.4.1 | Deskriptivni podatci | 135 |
| 5.4.2 | Testiranje razlika između eksperimentalne i kontrolne skupine..... | 140 |
| 5.4.3 | Testiranje razlika po godinama studija..... | 141 |
| 5.5 | Analiza rezultata provedenog testiranja za drugi tjedan eksperimentalnog programa | 142 |
| 5.5.1 | Deskriptivni podatci | 142 |
| 5.5.2 | Testiranje razlika između eksperimentalne i kontrolne skupine..... | 147 |
| 5.5.3 | Testiranje razlika po godinama studija..... | 148 |
| 5.6 | Analiza rezultata provedenog testiranja za prvi i drugi tjedan eksperimentalnog programa..... | 150 |
| 5.6.1 | Deskriptivni podatci | 150 |
| 5.6.2 | Testiranje razlika između eksperimentalne i kontrolne skupine..... | 152 |
| 5.6.3 | Testiranje razlika po godinama studija..... | 153 |
| 5.7 | Analiza rezultata provedenog testiranja za treći tjedan eksperimentalnog programa | 154 |
| 5.7.1 | Deskriptivni podatci | 154 |
| 5.7.2 | Testiranje razlika između eksperimentalne i kontrolne skupine..... | 161 |
| 5.7.3 | Testiranje razlika po godinama studija..... | 162 |
| 5.8 | Evaluacija | 163 |
| 5.8.1 | Mentalni napor | 163 |
| 5.8.2 | Kategorijalne varijable | 168 |
| 5.8.3 | Evaluacijska varijabla..... | 170 |
| 5.9 | Diskusija hipoteza | 171 |
| 6 | ZAKLJUČAK | 176 |
| 7 | LITERATURA | 183 |
| 8 | POPIS SLIKA | 208 |
| 9 | POPIS TABLICA..... | 210 |
| 10 | PRILOG A: PREDTEST..... | 213 |
| 11 | PRILOG B: ZADATCI ZA PRVI TJEDAN ISTRAŽIVANJA | 215 |
| 12 | PRILOG C: ZADATCI ZA DRUGI TJEDAN ISTRAŽIVANJA | 217 |
| 13 | PRILOG D: ZADATCI ZA TREĆI TJEDAN ISTRAŽIVANJA | 220 |
| 14 | PRILOG E: SKALA ZA SUBJEKTIVNU PROCJENU MENTALNOG NAPORA..... | 223 |
| 15 | PRILOG F: IZLAZNI EVALUACIJSKI UPITNIK | 224 |
| 16 | ŽIVOTOPIS | 226 |

1 UVOD

Prema nastavnom planu i programu (MZOŠ, 2006), jedno od temeljnih znanja i kompetencija budućih učitelja informatike u Republici Hrvatskoj su osnovna znanja i vještine programiranja iz raznih programskih jezika (Logo, BASIC, Pascal, Python). Na Učiteljskom fakultetu Sveučilišta u Zagrebu studenti modula informatike stječu stručno znanje iz određenog predmeta struke, specifično programiranja iz Logo jezika na petoj godini studija, te prolaze metodičku naobrazbu kako bi bili kompetentni u prijenosu programerskih znanja i vještina novim generacijama učenika ili programera početnika. Višegodišnje radno iskustvo autorice ovoga rada pružilo je uvid u probleme s kojima se studenti generacijama susreću u procesu učenja programiranja, gdje nakon slušanja kolegija početnog programiranja i dalje pokazuju nedovoljno znanja u razumijevanju i primjeni osnovnih programskih koncepata, struktura i algoritama. Učenje programiranja je kognitivno i socijalno kompleksan proces (Mayer, R. E., 1981). Iako su problemi univerzalni i poznati već 40 godina nije učinjen veći pomak u njihovom razrješavanju, a multi-institucionalna i multinacionalna istraživanja ističu kako se programiranje smatra jednim od sedam velikih izazova u računalnoj edukaciji (Caspersen, M. E., 2007). Prema nizu istraživanja u razdoblju između 1975.-2006. godine pokazalo se kako uspješno svladavanje gradiva iz kolegija u području početnog programiranja ovisi o mnogo faktora, kao što su metode učenja i poučavanja, razvoj formalnog i apstraktnog razmišljanja, broj odslušanih matematičkih, znanstvenih i strano-jezičnih predmeta u srednjoj školi, matematičko i logičko predznanje, kognitivni stil i stil učenja, upotreba mentalnih modela, iskustvo programiranja u nekom od programskih jezika, igranje video ili računalnih igara, samopouzdanje, motivacija i drugo (Bergin, S. i Reilly, R., 2006, prema Caspersen, M. E., 2007, str. 56-58). Pri tome je poseban naglasak stavljen na nastavne metode učenja i poučavanja (odabir programskog jezika ili paradigme jezika i strategije poučavanja), motivaciju studenata (Gomes, A. i Mendes, A. J., 2007), vještine rješavanja problema i logičkog razmišljanja, upotrebu održivih mentalnih modela (Bergin, S. i Reilly, R., 2006, prema Caspersen, M. E., 2007, str. 56-58) te matematičko i logičko predznanje (Byrne, P. i Lyons, G., 2001; Caspersen, M. E., 2007).

Metode i strategije poučavanja programiranja i programskih jezika dio su IKT poučavanja, čija metodologija do današnjih dana još nije čvrsto utvrđena (Varga-Papp, Z., Szlávi, P. i Zsakó, L., 2008). Poučavanje programiranja teklo je paralelno s razvojem tehnologije, ali je na edukacijskoj važnosti dobilo tek pojavom treće generacije viših programskih jezika (Szlávi, P. i Zsakó, L., 2003). Ključni zaokreti u metodologiji ili stilu

programiranja dogodili su se 70-tih godina 20-tog stoljeća, kada su započela i prva istraživanja računalnog programiranja na području kognitivne psihologije proučavanjem ljudskih kognitivnih procesa unutar raznih teorija i specifičnih koncepata, kao što su *sheme*, radna memorija, semantičke mreže, mentalni modeli i drugo (Mayer, R. E., 1981; Soloway, E. i Ehrlich, K., 1984; Hoc, J-M. i sur., 1990; Robins, A., Rountree, J. i Rountree, N., 2003). S aspekta kognitivne psihologije, proces programiranja zahtjeva upotrebu jezičnih vještina i složenih kognitivnih vještina, kao što su rasuđivanje, rješavanje problema i planiranje u zadanoj domeni znanja (Baldwin, L. P. i Kuljis, J., 2000). Takav proces obuhvaća simultano izvođenje niza mentalnih ili kognitivnih zadataka koji čine pozadinu za razumijevanje programa (engl. *program comprehension*), kao što su percepcija, posvećivanje pažnje relevantnim aspektima informacija, kratkotrajna pohrana informacija i dohvaćanje predznanja iz dugoročne memorije (Ormerod, T., 1990, str. 69). S aspekta računalne znanosti, proces programiranja obuhvaća poznavanje semantičkog znanja univerzalnih programskih koncepata (varijable, petlje, pokazivači, klase, objekti, rekurzija itd.), sintaktičkog znanja određenog programskog jezika (Shneiderman, B. i Mayer, R., 1979; Pair, C., 1990), vještinu dizajniranja algoritma ili postupka za rješavanje problema i vještinu prevođenja algoritma ili programskog kôda (engl. *coding*) u nekom programskom jeziku, te proces otkrivanja i otklanjanja pogrešaka (engl. *debugging*), (Pennington, N. i Grabowski, B., 1990; Rahmat, M. i sur., 2012).

Proces programiranja se temelji na zakonima matematičke logike. Kako ga je vrlo teško intuitivno povezati s fenomenima i procesima iz predmetnog okruženja (Narayanan, N. H. i Hegarty, M., 2002) često predstavlja nezanimljivi i demotivirajući aspekt studijskog obrazovanja (Kasurinen, J., Purmonen, M. i Nikula, U., 2008). Zbog apstraktne naravi programiranja i djelomično vizualne naravi ljudskih kognitivnih procesa (Ben-Ari, M., 2001, prema Sorva, J., 2012), u posljednjih 40 godina posebna je pozornost posvećena upotrebi vizualizacije u procesu usvajanja programerskog znanja (Naps, T. L. i sur., 2002; Ma, L., 2007; Kasurinen, J., Purmonen, M. i Nikula, U., 2008; Fouh, E., Akbar, M. i Shaffer, C. A., 2012). Pri tome se posebno ističu upotreba softverskih vizualizacija (Caspersen, M. E., 2007; Sorva, J., 2012), u formi obrazovnih sustava i okruženja za programsku i algoritamsku vizualizaciju (Byrne, M. D., Catrambone, R. i Stasko, J. T., 1999; Myller, M. i Bednarik, R., 2006; Lahtinen, E., Järvinen, H.-M. i Melakoski-Vistbacka, S., 2007; Hundhausen, C. D. i Brown, J. L., 2007; Tekdal, M., 2013; Osman, W. I. i Elmusharaf, M. M., 2014), te multimedijских instruktivnih prikaza kao sinergije multimedijskog dizajna i računalnih algoritama (Kehoe, C., Stasko, J. i Taylor, A., 2001; Narayanan, N. H. i Hegarty, M., 2002;

Bennedsen, J. i Caspersen, M. E., 2005; Matthíasdóttir, Á., 2006; Shehane, R. i, Sherman, S., 2014). Primjena vizualizacije omogućila je lakše formiranje i modificiranje kognitivnih struktura znanja odnosno održivih mentalnih modela programskih koncepata (Ben-Ari, M., 2001, prema Ma, L., 2007), što se pokazalo jednim od ključnih faktora u unaprjeđenju programerskog znanja (Mayer, R. E., 1981; du Boulay, B., O'Shea, T. i Monk, J., 1999; Ma, L., 2007). U domeni razvoja i primjene multimedija, kao kognitivnog pomoćnog sredstva za usvajanje znanja na raznim područjima, posebno se istaknula *kognitivna teorija multimedijskog usvajanja znanja* (engl. *cognitive theory of multimedia learning*), američkog edukacijskog psihologa Richarda E. Mayer-a (2001, 2005, 2014a). Teorija ističe upotrebu vizualnih i verbalnih informacija, u formi *multimedijske instruktivne poruke*, radi unapređenja procesa zapamćivanja i razumijevanja sadržaja, gdje ishod kognitivne obrade informacija čini konstrukcija verbalnih i slikovnih mentalnih predodžbi i njihovo povezivanje sa već postojećim znanjem pohranjenim u dugoročnoj memoriji (Mayer, R. E., 2014a). Prema ovoj teoriji, aktivna obrada informacija nastaje kada se pojedinac angažira u kognitivne procese kako bi razumio prikazani sadržaj. Takav aktivni proces usvajanja znanja promatra se kao proces izgradnje kognitivnih struktura znanja (engl. *knowledge structures*) ili mentalnih modela odgovarajućih koncepata koji predočuju esencijalne dijelove prikaza multimedijske poruke i relacije između tih prikaza (Mayer, R. E., 2001). Do sada, većina istraživanja *kognitivne teorije multimedijskog usvajanja znanja* provedena su na području učenja čitanja i pisanja, povijesti, matematike, kemije, meteorologije, jezika i drugo (Mayer, R. E., 2001, 2005, 2014a). Međutim, vrlo je malo istraživanja posvećeno učenju programiranja ili računalnih programskih jezika koja bi se temeljila na spomenutoj teoriji.

Ova doktorska disertacija prikazuje razvoj i praktičnu realizaciju *multimedijske instruktivne poruke za programski jezik Logo* (MIPL) za učenje osnovnih pojmova programskog jezika Loga kod studenata razredne nastave, budućih učitelja informatike. MIPL se temelji na objedinjavanju načela *kognitivne teorije multimedijskog usvajanja znanja* i načelu raščlanjivanja definiranog prema *modelu kognitivnog procesa multimodalnog razumijevanja* (engl. *cognitive process model of multimodal comprehension*).

1.1 Cilj i hipoteze istraživanja

Cilj je ovomu istraživanju bio ispitati učinkovitost *multimedijske instruktivne poruke za programski jezik Logo*, kod studenata razredne nastave, budućih učitelja informatike.

U namjeri ispitivanja razlika u zapamćivanju i razumijevanju sadržaja, razvijen je obrazovni sadržaj, nastao na osnovnim pojmovima iz odabranih nastavnih tema programskog jezika Logo, u formi multimedijske instruktivne poruke utemeljene na načelima *kognitivne teorije multimedijskog usvajanja znanja* (kontrolna skupina), s nadopunjenim načelom raščlanjivanja *modela kognitivnog procesa multimodalnog razumijevanja* (eksperimentalna skupina).

Hipoteze istraživanja:

(H1) Studenti koji koriste multimedijsku instruktivnu poruku s primjenom načela raščlanjivanja postižu bolje rezultate pri rješavanju niza zadataka objektivnog tipa u zapamćivanju i razumijevanju sadržaja, nego studenti koji koriste poruku bez primjene načela raščlanjivanja.

(H2) Studenti koji koriste multimedijsku instruktivnu poruku s primjenom načela raščlanjivanja postižu bolje rezultate pri rješavanju niza zadataka objektivnog tipa u zapamćivanju i razumijevanju sadržaja za koji je izlazna vrijednost geometrijska vrsta podataka, nego studenti koji koriste poruku bez primjene načela raščlanjivanja.

(H3) Studenti koji koriste multimedijsku instruktivnu poruku s primjenom načela raščlanjivanja postižu bolje rezultate pri rješavanju niza zadataka objektivnog tipa u zapamćivanju i razumijevanju sadržaja za koji je izlazna vrijednost negeometrijska vrsta podataka, nego studenti koji koriste poruku bez primjene načela raščlanjivanja.

1.2 Doprinis istraživanja

Znanja i vještine uspješnog učitelja informatike obuhvaćaju dva aspekta: kognitivni, način na koji pojedinac usvaja znanje i programersko-metodički, znanje koje pojedinac treba steći kako bi uspješno poučavao druge. Oblikovanje i razvoj *multimedijske instruktivne poruke za programski jezik Logo* (MIPL), u okviru ove doktorske disertacije, objedinjuje oba gore navedena aspekta.

(1) Kognitivni – vrlo je malo istraživanja u primjeni *kognitivne teorije multimedijskog usvajanja znanja* (KTMUZ) posvećeno učenju programiranja ili računalnih programskih jezika. Ovo je prvi rad koji prikazuje razvoj i primjenu *multimedijske instruktivne poruke* kao kognitivno pomoćno sredstvo za usvajanje osnovnih pojmova programskog jezika Logo, utemeljene na empirijski utvrđenim načelima

KTMUZ-a (Mayer, R. E., 2001, 2005, 2014a) i dodatnom *načelu raščlanjivanja* iz područja algoritama i strukture podataka, definiranom prema *modelu kognitivnog procesa multimodalnog razumijevanja* (Narayanan, N. H. i Hegarty, M., 2002). Novija istraživanja ističu da učinkovitost multimedijske instruktivne poruke uvelike ovisi o samoj strukturi sadržaja u odnosu na korišteni medij, te je stoga u radu opisana primjena načela raščlanjivanja nad elementarnim operacijama, konceptima i strukturama u različitim sadržajima Logo jezika, koristeći statičnu i/ili pokretnu sliku, govoreni i/ili pisani tekst, radi ispitivanja njegova utjecaja na zapamćivanje i razumijevanje sadržaja.

- (2) Programersko-metodički – većina istraživanja Logo jezika u svijetu bila je usmjerena na razvoj kognitivnih sposobnosti kod učenika mlađeg školskog uzrasta. Malo je istraživanja provedeno sa studentima (Lee, M. O. C., 1991; Fay, A. L. i Mayer, R. E., 1994), a još manje s budućim učiteljima informatike. Ovaj rad prikazuje razvoj i primjenu MIPL-a koji služi samorefleksiji budućih učitelja u njihovom logičkom, matematičkom i informatičkom znanju za teme koje će provoditi u nastavi informatike.

1.3 Pregled radnje

Doktorski rad je podijeljen u 6 poglavlja.

Prvo poglavlje sadržava uvod radnje, cilj i hipoteze istraživanja te doprinos istraživanja.

Drugo poglavlje sadržava pregled literature u znanstvenim područjima koja čine teorijski okvir doktorske radnje te glavne smjernice za cilj i plan istraživanja, metodologiju i interpretaciju rezultata. Poglavlje opisuje razvoj, karakteristike, strukturu i relevantna istraživanja iz programskog jezika Logo. Prikazani su i objašnjeni elementi i empirijska istraživanja *kognitivne teorije multimedijskog usvajanja znanja* i *modela kognitivnog procesa multimodalnog razumijevanja*, na čijim se načelima temelji razvoj *multimedijske instruktivne poruke za programski jezik Logo*.

Treće poglavlje sadržava razvoj *multimedijske instruktivne poruke za programski jezik Logo* (MIPL) koja se koristila kao konceptualni model u eksperimentalnom programu dokorskog istraživanja za ispitivanje učinka na unaprjeđenje zapamćivanja i razumijevanja sadržaja za učenje. Razvoj poruke obuhvaća analizu primijenjenih načela *kognitivne teorije multimedijskog usvajanja znanja* i opisa realizacije načela raščlanjivanja primijenjenog nad

osnovnim pojmovima programskog jezika Logo u trima nastavnim cjelinama. Digitalni zapis MIPL-a pohranjen je na CD mediju u formi priloga.

Četvrto poglavlje metodološki opisuje instrumente korištene u istraživanju, materijale, uzorak istraživanja i plan istraživanja.

Peto poglavlje predstavlja kvalitativnu i kvantitativnu analizu i interpretaciju rezultata istraživanja.

U **šestom poglavlju** sadržani su zaključak, sažetak istraživanja te opis teorijskih i praktičnih implikacija i prijedlozi za buduća istraživanja.

2 PREGLED LITERATURE

Teorijski okvir doktorske radnje temelji se na relevantnoj literaturi iz *programskog jezika Logo*, *kognitivne teorije multimedijskog usvajanja znanja* (engl. *cognitive theory of multimedia learning*) i *modela kognitivnog procesa multimodalnog razumijevanja* (engl. *cognitive process of multimodal comprehension*). Ovo poglavlje sadrži sustavni pregled definicija, koncepata i empirijskih istraživanja iz navedenih područja.

2.1 Programski jezik Logo

Poglavljje opisuje razvoj programskog jezika Logo, karakteristike i strukturu jezika te sažeto predstavlja relevantna istraživanja.

2.1.1 Povijesni razvoj Logo jezika

Programski jezik Logo razvijen je 1966. godine kao viši programski jezik treće generacije. Godine 1967. objavljen je prvi dokument o Logo jeziku u formi tehničkog memoranduma pod nazivom *The Logo System: Preliminary Manual* (Feurzeig, W., 2010). Namjera autora Logo jezika bila je razviti programski jezik pristupačan mlađim uzrastima specifično namijenjen za istraživanje ideja i procesa na području matematike, jezika, znanosti, glazbe, umjetnosti i računalnih vještina (Agalianos, A., Whitty, G. i Noss, R., 2006; Feurzeig, W., 2010). U to doba, između 1968.-1969. godine, većina je programskih jezika bila neadekvatna za primjenu u obrazovanju i poučavanje programiranja, jer su im nedostajali modularnost, rekurzivnost, semantička transparentnost i proceduralnost. Također, imali su vrlo slabo razvijene mogućnosti izvođenja programa te otkrivanja i otklanjanja pogrešaka (engl. *debugging*). Većina njih se dizajnirala za upotrebu raznih računalnih aplikacija na području matematike, znanosti i inženjerstva. U tu skupinu jezika ulazili su FORTRAN, APL, JOSS (ili dijalekti TELCOMP, CAL, PIL/I). Neki od njih su se naknadno mijenjali u vrlo maloj mjeri kako bi se prilagodili obrazovnim potrebama. Nekoliko jezika, posebice BASIC, dizajnirani su za poučavanje programiranja radi razvoja vještina rješavanja problema.

Struktura Logo jezika razvijena je iz LISP-a, jezika umjetne inteligencije (Feurzeig, W., 2010) i trebala je utjeloviti matematičke koncepte te omogućiti razvoj numeričkih i ne-numeričkih matematičkih algoritama. Feurzeig i sur. (1969) željeli su razviti jezik koji bi

učenicima olakšao usvajanje matematičkih pojmova (varijabla, funkcija, jednačba i drugo) kroz programske koncepte i sam proces programiranja. Prema njima, Logo jezik trebao je biti:

- dostupan učenicima mlađeg uzrasta koji nisu usvojili matematički način razmišljanja kroz tradicionalnu nastavu;
- sintaktički jednostavan u korištenju i pisanju osnovnih procedura;
- organiziran kako bi olakšao poopćenje i proširenje matematičkih algoritama, od jednostavnih ka složenijima;
- strukturiran kako bi obuhvatio matematički važne koncepte i podržao razvoj konstruktivističkog načina poučavanja.

Prvu verziju programskog jezika Logo, 1966. godine razvili su autori Seymour Papert, Wally Feurzeig i Danny Bobrow u *Educational Technologies Laboratory of Bolt, Beranek and Newman Corporation (BBN)*. Ime „Logo“ dobio je po grčkoj riječi 'λόγος' [logos], što znači „riječ ili oblik koji izražava misao; i samu misao“ (Feurzeig, W., 2010, str. 5). Seymour Papert razvio je inicijalne funkcionalne specifikacije, a Dan Bobrow izvršio prvu implementaciju u LISP jeziku, na SDS 940 računalu. Prva verzija Loga implementirana je 1967. godine, u *Hanscom Field School*, Lincoln, Massachusetts, među učenicima petih i šestih razreda. U razdoblju od 1967.-1968. godine razvijena je nova proširena verzija jezika koju je implementirao softverski inženjer Charles R. (Bob) Morgan na DEC PDP-1 računalu (Feurzeig, W., 2010).

Logo je trebao predstavljati katalizator vrlo dubokih i radikalnih promjena u edukacijskom sustavu kao inovativno računalno okruženje primarno orijentirano na poticanje aktivnog načina razmišljanja kod učenika u procesu usvajanja znanja (Papert, S., 1984). Međutim, unutar inicijalne razvojne skupine istraživača stvorene su dvije struje. Jedna skupina smatrala je Logo jezik evolucijskim korakom unutar postojećeg nastavnog kurikula, gdje se Logo trebao koristiti u raznim predmetima, od osnovne škole do fakulteta, unutar odgovarajućeg laboratorijskog okruženja kao pomoćni interaktivni alat za poticanje formalnog načina razmišljanja učenika još od rane dobi. To je zahtijevalo formiranje odgovarajuće „Logo kulture“ među učiteljima, obuku učitelja i prilagodbu nastavnih materijala. Druga skupina istraživača smatrala je Logo nekompatibilnim s postojećim tradicionalnim odgojno-obrazovnim sustavom, svojevrsnim „anti-školskim“ revolucionarnim projektom koji je vršio pritisak prema heurističkom, intuitivnom, kvalitativnom i iskustvenom

pristupu u povezivanju matematičkih i znanstvenih ideja (Agalianos, A., Whitty, G. i Noss, R., 2006).

Godine 1969., Seymour Papert, Wally Feurzeig, Danny Bobrow i Cynthia J. Solomon godine objavili su dokument pod nazivom *Programming-Languages as a Conceptual Framework for Teaching Mathematics*, s opisom petnaestomjesečnog istraživanja na području razvoja novog matematičkog kurikula isključivo utemeljenog i dizajniranog na upotrebi računala i programskog jezika Logo (Feurzeig, W. i sur., 1969). U glavnom dijelu istraživanja sudjelovali su učenici sedmog razreda, iako je istraživanje u kasnijem razdoblju provedeno i s učenicima drugog i trećeg razreda. Dokument sadrži opis razvoja Logo sadržaja za učenje matematičkih pojmova (numerički sustavi, funkcije, algebra, logika i drugo) i strategija rješavanja problema, detaljni opis nastavnih sati i igara korištenih u sklopu istraživanja te aktivnosti učenika za vrijeme programiranja u Logo jeziku. Učenici sedmog razreda koji su koristili Logo jezik pokazali su pozitivne promjene u svom radu naspram kontrolne skupine, specifično u razvoju tehničkog vokabulara, sposobnosti čitanja, razumijevanju grafova i tablica te aritmetičkih pojmova. S druge strane, kontrolna skupina je pokazala bolje rezultate u pisanju velikih slova, interpunkciji, čitanju mapa i razumijevanju aritmetičkih problema. Prema rezultatima, učenici drugog i trećeg razreda su s lakoćom usvojili osnovne elemente Logo jezika, iako većina njih nije bila u stanju u tako kratkom vremenskom razdoblju naučiti pisati složenije programe te razviti vještine otkrivanja i otklanjanja programskih pogrešaka.

Iste godine, dio istraživača iz revolucionarne skupine slijedio je Paperta u osnivanju Laboratorija za umjetnu inteligenciju (engl. *Artificial Intelligence Laboratory*) na MIT-u (engl. *Massachusetts Institute of Technology*) (Agalianos, A., Whitty, G. i Noss, R., 2006, str. 8) gdje se nastavio istraživački rad na Logo jeziku, dok je BBN skupina istraživača ostala brojčano mala i financijski nepotkrijepljena (većinu financija dobivala je iz *NSF – US National Science Foundation*). Godine 1971., Mike Paterson predstavio je Logo-kontrolirani robot-kornjaču (engl. *floor turtle*) spojenog kabelom na računalo. Zadavanjem Logo naredbi, učenici su određivali smjer kretanja robota (naprijed i nazad za određenu udaljenost; lijevo i desno za određeni kut) i iscrtavanje geometrijskih oblika upotrebom olovke za crtanje i senzora za detektiranje prepreka. Godine 1972. „kornjača“ je kao pomoćni grafički pokazivač na zaslonu računala prvi put predstavljena na MIT-u. U razdoblju između 1971.-1974. godine BBN skupina je proširila Logo jezik na više od 100 sveučilišta i istraživačkih centara (Feurzeig, W., 2010). Vremenom, NSF je prestala financirati BBN skupinu i postavljala sve veći pritisak na Logo MIT istraživački rad tražeći dokaze o odgojno-obrazovnoj vrijednosti Logo jezika. Međutim, MIT Logo skupina je smatrala standardne testove ispitivanja

neadekvatnim načinom utvrđivanja ljudske inteligencije i obrazovnih postignuća. Testove su promatrali isključivo kao metodu utvrđivanja stupnja ljudske percepcije na određenom području i očekivali su poboljšanja na rezultatima standardnog testiranja iz čitanja, umjetnosti i računalnih vještina unutar Logo okruženja. Kako se to nije ostvarilo, pretrpjeli su velike financijske rezove od NSF-a 1977. godine (Noss, R. i Hoyles, C., 1996, str. 180-181, prema Agalianos, A., Whitty, G. i Noss, R., 2006, str. 12). Tih godina pridružio im se veći broj inženjera i znanstvenika, kao što su Edith Ackerman, John Berlow, Paul Goldenberg i Daniel Watt. Došlo je do ponovnog razdvajanja istraživača unutar MIT skupine na reformatore i već postojeće revolucionare. Reformatori nisu željeli imati ikakve veze sa školskim sustavom radeći alternativne projekte i ulažući u tehnički razvoj i poboljšanje Logo okruženja. Revolucionari (učitelji) bili su zainteresirani za diseminaciju postojećih produkata i ideja po školama. NSF je podržavala revolucionarnu skupinu istraživača i vršila pritisak za implementacijom i testiranjem postojećih projekata. Tenzije su rasle i oko specifičnih tehničkih detalja jezika, kao što su definiranje sintakse, određivanje funkcionalnosti naredbi i pitanje nasljeđivanja intelektualnih prednosti od roditeljskih jezika (LISP-SCHEME). Oni koji su smatrali Logo jezikom primarnim za matematičko obrazovanje, „čistoća naslijeđa“ bila je ključ njegove estetike (Agalianos, A., Whitty, G. i Noss, R., 2006, str. 13). Drugi su pak smatrali da će „čistoća naslijeđa“ utjecati na sposobnost razumijevanja jezika. Postojanje dvaju estetskih prioriteta: učenosti i integriteta (matematička čistoća) definirali su daljnji razvoj Logo jezika. Seymour Papert je želio ostvariti sintaksu jezika koja će biti razumljivija djeci u skladu s njihovim načinom razmišljanja (npr. izraz „MAKE A 5“), radije nego zadržavajući matematičku notaciju (npr. izraz „LET A BE 5“).

Tih godina mnoge škole u Americi nisu imale mikroračunala, pa je primjena Logo jezika čekala rane 80-te kako bi iz eksperimentalne faze prešla u tradicionalno školsko okruženje. Logo je korišten u matematici, računalnoj znanosti, računalnoj lingvistici od osnovnih razreda do preddiplomskih kolegija (Feurzeig, W., 2010). Tu su se uključile razne hardverske i softverske tvrtke kako bi pokušale iskoristiti školsko tržište. Razni pokušaji komercijalizacije Loga imali su pozitivne i negativne implikacije. S pozitivne strane Logo je postao dostupan široj publici čime se pojavio pritisak za uvođenjem jezika u nastavno okruženje. S negativne strane proklamirale su se nerealistične i empirijski neutvrđene tvrdnje oko Logo jezika koje su se mogle pronaći i u ranoj znanstvenoj literaturi (Agalianos, A., Whitty, G. i Noss, R., 2006). U to doba, veću su dominaciju zadržavali jezici BASIC i PASCAL, kao jezici za naprednije aplikacije i veće uzraste. Smatralo se da Logo pripada mlađoj generaciji, dok C, PASCAL, FORTRAN i BASIC starijoj, što je bila najveća

predrasuda nastala marketingom. Jedan od dijalekata Logo jezika, Microworlds Logo, žrtvovao je originalnu estetiku Logo jezika u ime „marketinškog kiča“ (Agalianos, A., Whitty, G. i Noss, R., 2006, str. 17). *Logo Copmuter Systems Inc.* razvio je *Logo Writer* 1986. godine kao dijalekt Logo jezika koji je obuhvaćao razne mogućnosti grafičkog dizajna i programa za obradu teksta. Time se željelo ukazati na naprednije mogućnosti Logo jezika, iako je po nekim istraživačima to značilo degradaciju matematičke i geometrijske strane jezika (smanjena je rezolucija kornjačine grafike, pojačane su linije iscrtavanja što je umanjilo grafičke mogućnosti), (Agalianos, A., Whitty, G. i Noss, R., 2006, str. 18). Sredinom 80-tih nastala je Logo verzija za *Apple* računala: *Apple Logo*, kao nova marketinška odluka. Uskoro su se pojavile i dvije natjecateljske verzije Loga za *Apple* računala – LCSI Logo i Terrapin Logo (razvijen na MIT-u). 80-tih godina Logo se proširio u Englesku. Četiri implementacije Logo dijalekata za BBC računala s dvije natjecateljske verzije razvijene su godine 1984. – *Acorn* i francuska verzija *Logotron Logo*. U to vrijeme, određena skupina amatera uvidjela je financijsku priliku i kreirala male grafičke pakete za crtanje napisane u BASIC jeziku. Jedan od tih paketa bio je *Logo-Challenge (DART)*. Kako je *DART* bio jeftiniji od izvornog Logo programa većina učitelja odlučila se za njega. U konačnici, marketinški lanac degradirao je Logo jezik na razinu programa „kornjačine grafike“ (Agalianos, A., Whitty, G. i Noss, R., 2006, str. 27), ali je otvorio put razvoju vizualnih okruženja za poučavanje programiranja sa smanjenim naglaskom na razumijevanju sintakse koja je predstavljala temeljeni problem kod programera početnika. Feurzeig i kolege iz BBN-a razvili su 1980. godine vizualno Logo programsko okruženje *Function Machines* dizajnirano za učenje i poučavanje matematike. Poslije je razvijeno više od 130 implementacija vizualnih okruženja, kao što su *GeomLogo*, *Boxer*, *StarLogo*, *NetLogo*, *Imagine*, *Elica* i *Scratch*, *BYOB* koja imaju vizualno korisničko sučelje i omogućuju objektno orijentirane animacije, 3D grafiku i simulacije (Feurzeig, W., 2010; Jenkins, C. W., 2012).

2.1.2 Karakteristike Logo jezika

Seymour Papert, jedan od vodećih autora Logo jezika je pod utjecajem svog mentora Jean Piageta tražio nove metode poučavanja i adekvatne tehnologije kao sredstvo za kognitivni razvoj djeteta (Ackermann, E., 2009). Za razliku od Piageta, vjerovao je kako kulturološko bogati računalni sadržaji za učenje matematike mogu konkretizirati stupanj formalnih operacija misaonog razvoja djeteta te pomaknuti granice koje razdvajaju konkretnu od formalne faze i time akcelerirati konstrukciju kognitivnih struktura znanja kod djece ranije

dobi (Papert, S., 1993, str. 21; Gillespie, C. W., 2004). Smatrao je školu umjetnim i neučinkovitim okruženjem za učenje. Prvotno je svoje tvrdnje postavio u odnosu na postojeći matematički kurikulum istaknuvši kako matematičko okruženje za učenje ne sadrži humanistički pristup te je u suštini disocirano od samog čovjeka (Papert, S., 1993, str. 39). Kritizirao je matematičke metode poučavanja kao sredstva za pamćenje sadržaja bez razumijevanja (Papert, S., 1993, str. 47). U svojim se istraživanjima isključivo usmjerio na sam proces učenja ističući kako „biti inteligentan“ znači biti senzibilan i empatičan prema promjenama vanjskog okruženja te se osobno povezati s fenomenom istraživanja (Ackermann, E., 2009). Svoju je teoriju učenja nazvao *konstrukcionizam*, gdje djeca metodom samootkrivanja stječu znanja iskustvenim učenjem unutar određenog konteksta i konstrukcijom vlastitih „objekata za razmišljanje“ (engl. „*object-to-think-with*“) (Papert, S., 1983). Kroz te objekte projiciraju ideje i osjećaje u predmetni svijet, čine ih opipljivima i pristupačnima drugima. Diseminacijom i analizom ideja primaju povratne informacije na temelju kojih preoblikuju i izoštravaju vlastite mentalne modele jer „*djeca uče čineći i razmišljajući o vlastitim aktivnostima*“ (Papert, S., 2005, str. 353). U suštini, „*objekti predstavljaju sjecište kulturološke prisutnosti, ugrađenog znanja i mogućnosti za osobnu identifikaciju*“ (Papert, S., 1983, str. 11). Godine 1980. objavljeno je prvo izdanje Papertove knjige *Mindstorms: Children, Computers and Powerful Ideas* (Papert, S., 1983) koja opisuje razvoj, filozofiju i karakteristike Logo jezika te njegove kognitivne, afektivne i socijalne aspekte. Programski jezik Logo predstavljao je utjelovljenje Papertove teorije učenja kao virtualno grafičkog okruženja u kojem djeca stječu potrebna matematička iskustva upotrebom načela „Kornjačine Geometrije“ (engl. *Turtle Geometry*) u procesu kreiranja geometrijskih likova (Papert, S., 1983, str. 11). Jedina uloga „kornjače“, kao grafičkog ili fizičkog objekta (robot), bila je poslužiti kao model ili „objekt za razmišljanje“ (engl. *object-to-think-with*) u konstrukciji drugih objekata. Prema Papertu, Logo je „prijateljski“ (engl. *friendly*) jezik jer se komunikacija s korisnikom odvija upotrebom jednostavnih i lako razumljivih engleskih riječi. U programiranju kretanja „kornjače“ djeca simultano osvještavaju i ispravljaju svoja konceptualna shvaćanja zadanog problema te razvijaju vještine otkrivanja i otklanjanja programskih pogrešaka. Računalna procedura koja trenutno ne izvršava željenu funkciju u procesu programiranja ne smatra se neuspjehom već intelektualnim izazovom (Kieren, T. E., 1984, str. 12). Pri tome, grafičko okruženje programa služi kao virtualni prostor za refleksiju misaonih postupaka i istraživanje vlastitog mišljenja (Papert, S., 1983, str. 19), odnosno prostor za razvoj metakognitivnih vještina. U početnoj fazi programiranja, upravljanje pomacima „kornjače“ izvodi se zadavanjem i trenutnim izvođenjem pojedinačnih naredbi

unutar grafičkog okruženja programa. Kako je Logo interaktivan jezik, program automatski ispisuje moguće pogreške i korisnik može provjeriti mogućnost realizacije vlastite ideje. Kod naprednije razine programiranja i rješavanja složenijih programskih zadataka naredbe se povezuju u listu i zapisuju u formi većih programskih struktura ili procedura. U procesu debugiranja povratne poruke programa ne prikazuju sintaktičke pogreške (engl. *syntax error*) već eksplicitno i opsežno ispisuju što je potrebno ispraviti (npr. „*nema dovoljno ulaznih podataka za izvođenje naredbe FORWARD*“). Na taj način odvija se „komunikacija“ između korisnika i programa koja stvara svojevrstan osjećaj kontrole i izgrađuje samopouzdanje (Papert, S., 1983, str. 61). Mogućnost vizualizacije razvoja programskoga kôda ujedno omogućuje korisniku i vizualno praćenje vlastitih kognitivnih aktivnosti (Lehrer, R., Lee, M. i Jeong, A., 1999), te pomažu u razvoju apstraktnoga načina razmišljanja (Lee, M. O. C., 1991). S matematičkog aspekta primjene Logo jezika, Papert u knjizi iznosi koncept „*syntonic*“ učenja preuzetog iz kliničke psihologije koji se odnosi na djetetovo osvještavanje tijela oponašanjem i sinkroniziranjem vlastitih pokreta s pomacima „kornjače“ (engl. *body syntonic*) (Kieren, T. E., 1984, str. 16). Posebno ističe kako je „kornjačina“ geometrija „*ego syntonic*“ jer je sinkronizirana s procesom razmišljanja djeteta tijekom izgradnje geometrijskih ideja (crtanje geometrijskog kuta definira se načinom i brojem okretaja). „Kornjačina geometrija“ je lokalna geometrija, vidljiva i izvršena s unutarnjeg, osobnog gledišta djeteta. „*Ego syntonic*“ koncept je u suštini povezan sa osobnom percepcijom djeteta kao ljudskog bića koje ima svoje „*namjere, ciljeve, želje, sviđanja i nesviđanja*“ (Papert, S., 1983, str. 63). Prema Papertu, dijete osjeća ponos i motivaciju jer koristi računalo iz vlastitih motiva i želja, bez vanjske prisile. Također, posljedica „*ego syntonic*“ koncepta je mogućnost kreiranja i manipulacije mentalnim prikazima tijekom razvoja geometrijskih ideja čija se vjerodostojnost provjerava u grafičkom prozoru programa.

Drugi važan koncept koji Papert iznosi je „mikrosvijet“ (emgl. *microworld*) ili svijet matematike (engl. *Mathland*) kao mjesto za stjecanje matematičkih iskustava te prostor za rast „*ideja ili intelektualnih struktura*“ (Papert, S., 1983, str. 125). Papertova knjiga postavila je temelje za razne obrazovne tehnološke proizvode, danas poznate kao LEGO/Logo i Lego Mindstorms igračke koje potiču usvajanje znanja na području matematike i mehanike kroz razne ručne aktivnosti, kao što su izgradnja robota i Lego modela (Harel, I. i Papert, S., 1991, prema Tsang, C., 2004). LEGO/Logo se temelji na realizaciji Papertovog virtualnog mikrosvijeta upotrebom mehaničkih i elektroničkih komponenti. Kao rezultat suradnje između MIT-a i Lego Company razvijene su interaktivne igračke koristeći Lego gradivne elemente (engl. *Logo bricks*) i računalnu tehnologiju pod nazivom *Behaviour Construction*

Kits (Resnick, M., 1993, prema Tsang, C., 2004), što predstavlja evoluciju „inteligentnog konstrukcijskog bloka“ (engl. *Programmable Brick*) kao pomoć u konstruktivističkom usvajanju znanja. „Inteligentni konstrukcijski blok“ čini integracija mikroprocesora i elektroničke logike s plastičnim Lego gradivnim elementima. Vremenom se „Inteligentni konstrukcijski blok“ razvio u *Lego Mindstorms* produkt i korišten je u mnogim MIT *Media Lab* istraživanjima sredinom 90-tih u svrhu izgradnje igračaka za konstruktivistički način učenja. Martin, F. i sur. (2000, prema Tsang, C., 2004) prikazali su evolucijski razvoj raznih MIT konstruktivističkih paketa za učenje, od prvotne kibernetičke kornjače (robota) iz 1970-tih sve do LEGO/Logo, *Programmable Brick* i *Mindstorms* proizvoda. Kako je primjena većine tih alata unutar nastavnih okruženja bila teško izvediva, mnogi *Mindstorms* proizvodi nisu doživjeli marketinški uspjeh (Tsang, C., 2004).

2.1.3 Struktura Logo jezika

Povijesni razvoj programskih jezika opisuje se kroz četiri generacije: strojni jezik prve generacije; niži simbolički jezik druge generacije ili assembler (engl. *assembler*); viši programski jezici treće generacije (npr. FORTRAN, ALGOL, COBOL, LISP, BASIC, LOGO, Pascal, C, C++, C#, Java i dr.) i jezici četvrte generacije (npr. Visual BASIC, Visual C++, Delphi, Python, Rubi, Perl, SQL i drugi). Prema metodologiji (paradigmi) ili stilu programiranja najčešće se dijele na proceduralnu (imperativnu), funkcijsku, logičku (deklarativnu) i objektno orijentiranu paradigmu, pri čemu neki jezici mogu imati karakteristike više paradigmi. Razlika između proceduralnih i funkcijskih ili logičkih jezika leži u pristupu računalnom procesu – dok prva paradigma određuje „kako“ izvršiti neki zadatak ili doći do rezultata, druge dvije opisuju „što“ treba izvršiti, odnosno „što“ čini domenom zadatka (Pair, C., 1990). Programski jezik Logo primarno pripada proceduralnoj paradigmi, ali podržava i funkcijsku paradigmu naslijeđenu od roditeljskog jezika LISP. U tablici 1 prikazana je instrukcijska struktura Logo jezika.

Tablica 1. Instrukcijska struktura Loga (Kieren, T. E., 1984, str. 5.; Papert, S. 1983, Kniewald, I., 2005)

| Način rada | Karakteristike |
|--|---|
| <p>Izravan (engl. <i>Direct Mode</i>)</p> | <p>Logo programski jezik namijenjen je za rad s RIJEČIMA i LISTAMA naredbi.</p> <p>Riječ upravlja određenom radnjom (pomak grafičkog pokazivača kornjače). Riječi mogu biti osnovne naredbe Logo jezika (FORWARD, BACK, RIGHT, LEFT i dr.) ili imena (varijabla, procedura). Lista naredbi određuje slijed radnji prilikom iscrtavanja složenijih grafičkih struktura.</p> <p>Tipovi podataka u Logu: numerički (brojevi), znakovni (alfanumerički znak – slovo (a, A, b, B...) i broj (0, 1, ..., 9); specijalni znakovi (+, -, *, /, ?, ! i dr.)), riječi i liste. Riječi su niz znakova (npr. SW007). Liste su niz raznovrsnih podataka koji se navode unutar uglatih zagrada (npr. [SW007 108 A109]).</p> |
| <p>Proces otkrivanja i otklanja pogrešaka u grafičkom prozoru (engl. <i>screen debugging</i>) upotrebom osnovnih naredbi (npr. FD, BK, CLEARSCREEN, PENERASE) – korisnik zadaje pojedinačnu naredbu ili listu naredbi i prema izvršenim pomacima grafičkog pokazivača kornjače donosi zaključak o ispravnosti rezultata.</p> <p>Proces uređivanja liste naredbi (engl. <i>list editing</i>) ili procedure – korisnik mijenja niz naredbi unutar procedure kako bi postigao traženi rezultat. Korisnik je u stanju identificirati i povezati određeni segment procedure sa pripadajućim slijedom radnji prema vizualnom prikazu u grafičkom prozoru programa. Lista naredbi mijenja se unutar procedure upotrebom uređivača teksta.</p> | |
| <p>Osnovni način rada (engl. <i>Naive Programming Mode</i>)</p> | <p>Logo je PROCEDURALAN programski jezik.</p> <ul style="list-style-type: none"> Programska struktura ili procedura je imenovana lista naredbi ili niz naredbi koje se pohranjuju u memoriju računala i koje računalu treba izvršiti, pri čemu se mijenja sadržaj memorije. Niz naredbi određuje „kako“ izvršiti neki programski zadatak, a ne „što“ izvršiti. Procedura se sastoji od ključnih riječi TO i END. Riječ „TO“ označava početak procedure, a riječ „END“ označava kraj procedure. Procedure se optimiziraju upotrebom petlji ili programskih struktura koje omogućuju ponavljanje niza naredbi zadani broj puta (REPEAT petlja, FOREACH petlja, FOR petlja) ili do promjene zadanog uvjeta (WHILE petlja). Uvjetnim grananjem (IF-THEN, IF-THEN-ELSE, TEST-IFT-IFF) ili naredbama odluke (IF, TEST) izvodi se niz naredbi pod zadanim (logičkim) uvjetima. <i>Bottom-Up</i> postupak (rješavanja problema, od specifičnog ka općem) – proučavanje rezultata izvođenja pojedinačnih programskih procedura (podproblema) radi pronalaženja općeg rješenja. Započinje na najnižoj razini apstrakcije radi izvođenja djelomičnih rješenja koji se potom koriste u procesu rasuđivanja tijekom rješavanja problema više razine. |
| <p>Proces otkrivanja i otklanja pogrešaka u grafičkom prozoru – uređivanje listi (engl. <i>list editing</i>).</p> | |

| | |
|--|---|
| <p>Napredni način rad (engl. <i>Planned Programming Mode</i>)</p> | <p>Logo je STRUKUTRNI programski jezik.</p> <ul style="list-style-type: none"> ▪ Upotreba procedura koje čine logičku organizaciju programa u skladu s misaonim postupcima programera. Procedure nastaju kao porodice drugih procedura upotrebom jedne ili više ulaznih vrijednosti ili varijabli (engl. <i>variable</i>). ▪ <i>Top-down</i> postupak (rješavanja problema, od općeg ka specifičnom) – proces raščlanjivanja složenih procedura (problema) na elementarne cjeline ili zasebne procedure (podprobleme) koje se po potrebi mogu koristiti kao gradivni blok za izgradnju većih procedura radi rješavanja složenijih problemskih zadataka. <p>Logo je REKURZIVNI programski jezik.</p> <ul style="list-style-type: none"> ▪ Rekurzivna procedura poziva samu sebe sve dok se ne ispuni zadani uvjet. Upotrebom rekurzije može se postići optimizacija programskoga kôda. ▪ Rekurzija olakšava proces programiranja u slučaju kada se određene naredbe (unutar programskih struktura, npr. FOR petlja) trebaju ponoviti veći broj puta sa sistematičnim promjenama parametara u svakom rekurzivnom prolazu. |
| <p>Proces otkrivanja i otklanja pogrešaka u grafičkom prozoru (engl. <i>screen debugging</i>) – uređivanje listi (engl. <i>list editing</i>) i logičko debugiranje (engl. <i>logic debugging</i>).</p> <ul style="list-style-type: none"> ▪ Kod složenijih procedura gdje postoji slabo vidljiva veza između manjih segmenata procedure (bloka naredbi) i konačnog rezultata (izvršene radnje unutar grafičkog prozora programa) korisnik treba biti u mogućnosti na jezičnoj/logičkoj razini pratiti tijek programa i uočavati pogreške. ▪ Proces zahtijeva dugogodišnje radno iskustvo u Logo jeziku i pruža mogućnost transfera znanja (analitičko i formalno razmišljanje) u ne-računalne domene. | |

2.1.4 Istraživanja na području Logo jezika

The Brookline LOGO Project (Papert, S. i sur., 1979) je jedan od prvih projekata koji je imao za cilj ispitati učinkovitost programskog jezika Logo. Na više od 200 stranica detaljno su opisane faze projekta, stilovi učenja 16 ispitanika, njihova iskustva te razvoj programskih i matematičkih (geometrijskih) vještina. U projektu je korištena strategija poučavanja samootkrivanjem prema pedagogiji Logo jezika, gdje je učitelj usmjeravao učenike koji su bili poticani na samostalni rad definiranjem zadataka i vođenjem dnevnika „vlastitih postignuća“. Proces programiranja se odvijao u dvije faze: (1) upotreba osnovnih naredbi za crtanje raznih geometrijskih formi i (2) prevođenje naredbi iz prve faze u složenije programske strukture ili procedure. Autori su dali interpretaciju aktivnosti ispitanika prema sedam kategorija: (1) stjecanje osjećaja za programsku naredbu; (2) razvijanje procedure; (3) razumijevanje rada procedure u odnosu na krajnji rezultat procedure; (4) usvajanje pojma

modularnosti; (5) *top-down* i *bottom-up* postupci rješavanja programskih problema; (6) pisanje procedura koristeći REPEAT petlju i rekurziju; (7) upotreba varijabli ili nepoznanica u procesu programiranja.

U razdoblju između 1979.-1993. godine provedena su intenzivna istraživanja radi ispitivanja učinkovitosti primjene programskog jezika Logo u procesu učenja matematike (Bamberger, 1984, prema Lee, M. O. C., 1991; Clements, D. H., 1986; Clements, D. H. i Battista, M. T., 1990; Harel, I., 1991, prema Tsang, C., 2004, str. 10; Olive, J., 1991; Au, W. K., 1992, str. 45; Clements, D. H. i Meredith, J. S., 1992; Sutherland, R., 1993), te njegova utjecaja na: (1) afektivne promjene kod učenika, kao što su motivacija, stav prema računalima, usvajanje matematičkih koncepata (Au, W. K., 1992, str. 49, 270-290); (2) oblike socijalne interakcije, kao što su komunikacija između učenika, komunikacija i rješavanje problema, komunikacija između djece i roditelja, učinak Loga na disciplinu i organizaciju (Harel, I., 1991, prema Tsang, C., 2004, str. 10; Au, W. K., 1992, str. 51, 270-290; Clements, D. H. i Meredith, J. S., 1992); (3) kognitivni i metakognitivni razvoj učenika, kao što su sposobnost logičkog rasuđivanja, kreativnost, razvoj vještina i vrsta strategija rješavanja problema te transfer vještina i znanja iz Logo okruženja u druge domene (Pea, R. D., 1983; Bamberger, 1984, prema Lee, M. O. C., 1991; Clements, D. H. i Gullo, D. F., 1984; Pea, R. i Kurland, D. M., 1984; Delclos, V., Littlefield, J. i Bransford, J. D., 1985, prema Lee, M. O. C., 1991; Emihovich, C., Miller, G. E. i Clare, V., 1985; Kurland, D. M. i Pea, R. D., 1985; Clements, D. H., 1986; Clements, 1987, prema Lee, M. O. C., 1991; Fay, A. L. i Mayer, R. E., 1987; Mayer, R. E. i Fay, A. L. 1987; Missiuna, C. i sur., 1987; Klahr, D. i Carver, S. M., 1988; Lehrer, R., Guckenberger, T. i Lee, O., 1988; Clements, D. H., 1990; Nastasi, B. K., Clements, D. H. i Battista, M. T., 1990; Lehrer, R. i Littlefield, J., 1991, 1993; Au, W. K., 1992, str. 55 i dr.). Ispitanici su se kretali u dobi od 4 do 12 godina (Au, W. K., 1992).

U većini istraživanja utvrđeno je kako Logo jezik može doprinositi procesu učenja matematike, osobito u poticanju pozitivnih promjena u stavovima učenika u odnosu na matematiku i unaprjeđenju razumijevanja određenih matematičkih koncepata (niz brojeva, varijable, svojstva poligona, mjerenje kutova, pravokutni koordinatni sustav, negativni brojevi i dr.) (Au, W. K., 1992, str. 48, 270-290). Pri tome je određeni broj istraživača istaknuo kako su nastavne strategije i vodstvo učitelja važni faktori u postizanju odgovarajućih ishoda učenja (Au, W. K., 1992, str. 48). Pozitivan učinak Logo programiranja uočen je i u razvoju metakognitivnih vještina (Au, W. K., 1992, str. 69, 270-290). Kontradiktorni rezultati dobiveni u istraživanjima utjecaja Logo jezika na afektivne promjene i kognitivni razvoj učenika, osobito kod ispitivanja utjecaja Logo programiranja na razvoj vještina rješavanja

problema i njihovih transfera u druge domene (Au, W. K., 1992, str. 44, 62), pripisivali su se višestrukim faktorima, kao što su način mjerenja izlaznih varijabli, struktura istraživanja (mali broj ispitanika i vrste istraživačkih metoda) i primjena različitih metoda poučavanja u istraživanju (Lee, M. O. C., 1991, str. 34; Au, W. K., 1992, str. 63, 70). Međutim, sredinom 80-tih istraživači su uvidjeli kako je temeljni uzrok kontradiktornih rezultata u ispitivanju utjecaja Logo programiranja na određene kognitivne ishode vrsta primijenjene Logo instrukcije u istraživanju (Kinzer, C. K. i sur., 1984; Au, W. K., 1992, str. 68-71), pri čemu su nastavne strategije vođenim otkrivanjem (engl. *guided instruction*) (Au, W. K., 1992, 71, 283-290; Fay, A. L. i Mayer, R. E., 1994, prema Mayer, R. E., 2004) pokazale veću učinkovitost u postizanju željenih kognitivnih učinaka, odnosno razvoju i transferu vještina rješavanja problema nego nastavna strategija samootkrivanjem (engl. *self-discovering learning*) (Au, W. K., 1992, str. 71, 270-283), kako su to zagovarali autori Logo jezika. Istraživanjima se ustanovilo da Logo jezik može imati pozitivan utjecaj na kognitivni stil (keativnost, divergentno razmišljanje) i vještine učenika (istraživanje, planiranje, analiza i predviđanje), razvoj prostornih sposobnosti i logičkog rasuđivanja, ali ne može značajno promijeniti općeniti kognitivni razvoj u djece mlađe dobi (Au, W. K., 1992, str. 59, 61, 270-290). Autori Littlefield i sur. (1988, prema Mayer, R. E., 2004) izvršili su trogodišnji projekt u kojem su ispitali utjecaj učenja Logo programiranja na kognitivni razvoj i stavove učenika, gdje su rezultati pokazali kako poučavanje metodom samootkrivanja nije razvilo programske vještine kod učenika. U nekoliko empirijskih studija autori su pokazali kako učenje vođenim otkrivanjem usmjeruje i olakšava učenikov proces razmišljanja i pridonosi razvoju vještina rješavanja problema te gradi mostove između Logo programiranja i rješavanja problema iz predmetnog okruženja, (Lee, M. O. C., 1991, str. 35). Autori Lehrer, Guckenberg i Sancilio (1988, prema Mayer, R. E., 2004) zaključili su kako je vođeno poučavanje preduvjet za transfer vještina iz Logo okruženja u druge domene. Vođeno poučavanje osobito se pokazalo učinkovitim u području rješavanja problema ili metakognicije (Au, W. K., 1992, str. 283-290). Autor Au (1992) je ispitao učinke programiranja programskih jezika Logo i Basic na razvoj vještina rješavanja problema i socijalnu interakciju kod učenika osnovne škole primjenjujući dva nastavna pristupa. U prvom pristupu (engl. *process-oriented*) orijentacija je bila na razvoju, izražavanju, organizaciji i implementaciji ideja u procesu pisanja programskog kôda, što podrazumijeva poučavanje programskog jezika s naglaskom na vještine rješavanja problema. U drugom pristupu (engl. *context oriented*) orijentacija je bila na poučavanju gramatičke i sintaktičke strukture jezika. Rezultati su pokazali kako Logo programiranje može olakšati razvoj vještina rješavanja problema i unaprijediti socijalnu

interakciju među učenicima. Također, pokazalo se kako prvi nastavni pristup s fokusom na procese rješavanja problema može unaprijediti razvoj tih vještina i njihov prijenos u druge domene. Lee (1991) je u svojoj doktorskoj disertaciji utvrdio kako poučavanje Logo programiranja vođenim otkrivanjem u odnosu na poučavanje samootkrivanjem utječe na razvoj kognitivnih i metakognitivnih vještina kod budućih učitelja. Autori Fay i Mayer (1994, prema Mayer, R. E., 2004) proveli su istraživanje sa 20 studenata u kojem je eksperimentalna skupina primila prethodnu obuku (engl. *pretraining*) oko dekompozicije programskih procedura na manje dijelove (engl. *modularity*) i korištenje istih procedura više puta (engl. *reusability*). Za vrijeme rada u Logo programu eksperimentalna skupina je pokazala prednost u odnosu na kontrolnu u kvaliteti pisanja programskog kôda. Međutim, nije bilo statistički značajnih razlika između skupina na kognitivnim testovima kao što su prostorne sposobnosti i razumijevanje instrukcija, što je potvrdilo kako je vještine programiranja moguće steći neovisno od sintakse određenog programskog jezika.

Metoda vođenog poučavanja pokazala se učinkovitijom u unaprjeđenju razumijevanja sadržaja zbog poticanja kognitivnih procesa ključnih za usvajanje znanja, kao što su organiziranje informacija u koherentne strukture i povezivanje istih sa predznanjem (Mayer, R. E., 2005), te izgradnja kognitivnih struktura (Bruner, J. S., 1961, prema Mayer, R. E., 2004). Pri tome, vođeno poučavanje nosi svoje izazove, jer učitelj treba znati odabrati strategiju vođenja, stupanj primjene instrukcije te definirati učeničko postignuće (Mayer, R. E., 2004, str. 17). U konačnici, pokazalo se kako najproduktivniji pristup poučavanju Logo jezika istovremeno obuhvaća vođeno poučavanje i mogućnost samostalnog aktivnog istraživanja i eksperimentiranja (Feurzeig, W., 2010).

2.2 Kognitivna teorija multimedijskog usvajanja znanja

U posljednja tri desetljeća na području edukacije intenzivnom primjenom IKT-a stvorena je sinergija između *multimedija* i računalnog okruženja što je rezultiralo razvojem raznih pomoćnih digitalnih alata, kao što su *multimedijski* udžbenici, enciklopedije, priručnici, igre, animacije, simulacije i dr. Pojam *multimedij* označava skup različitih vrsta informacija, kao što su tekst, slika, zvuk, video i animacija. Tumačenje pojma *multimedij* može imati više značenja. Sa stajališta tehnologije *multimedij* znači prikaz sadržaja korištenjem dva ili više prijenosnih sredstva (fizičkih sustava), kao što su računalni zaslon, zvučnici, projektori, video rekorderi, nastavna ploča i dr. Iako je tehnologija važna u praktičnom smislu radi prikaza i prijenosa informacija, proces razumijevanja *multimedijskih* prikaza primarno se temelji na učinkovitosti instrukcijske poruke prije nego o korištenom mediju, bilo da se radi o računalnom zaslonu ili tiskanoj knjizi (Mayer, R. E., 1997; 2003). Pri tome, faktori koji unaprjeđuju razumijevanje sadržaja isključivo ovise o vrsti i načinu prikaza informacija (Schnotz, W., 2014, prema Mayer, R. E., 2014a). U tom se slučaju tumačenje pojma *multimedij* preusmjeruje sa tehnologije (engl. *technology-centered*) na čovjeka i instrukcijski dizajn poruke kojim se potiču i usmjeruju ljudski kognitivni procesi obrade informacija (engl. *learner-centered*) radi smislenog usvajanja znanja. *Multimedij* kao način prikaza sadržaja (engl. *presentation modes*) podrazumijeva korištenje različitih načina prikaza, kao što su to riječi i slike. Ovo tumačenje pretpostavlja da su primatelji poruke sposobni koristiti različite kodne sustave za prikaz znanja, kao što su to verbalni (npr. naracija) i slikovni (npr. statična slika, animacija, video) prikazi bez obzira na vrstu medija (npr. digitalni *multimedij* ili tiskani udžbenik). Pri tome, istraživanja mentalnih predodžbi ističu kako su verbalni prikazi znanja kvalitativno drukčiji od slikovnih prikaza znanja. *Multimedij* kao način primanja informacija podrazumijeva korištenje dva ili više osjetilnih sustava (engl. *sensory modalities*) odnosno osjetilnih receptora za opažanje prikazanog sadržaja, kao što su to oči i uši. Ovdje se u obzir uzima ljudska sposobnost obrade prikazanog sadržaja pomoću dva odvojena kanala, slušnog i vizualnog.

2.2.1 Multimedijaska instruktivna poruka

Multimedijsko usvajanje znanja podrazumijeva stjecanje trajnih promjena u znanju pojedinca upotrebom *multimedijske instruktivne poruke* (Mayer, R. E., 2008). Multimedijaska instruktivna poruka je poruka koja se sastoji od simultanog prikaza riječi i slika, a može biti

prikazana koristeći tradicionalno ili računalno sredstvo prijenosa (Mayer, R. E., 2005). Pojam *riječi* uključuje govoreni (naracija) i/ili pisani tekst. Pojam *slike* uključuje statičnu sliku (npr. ilustracija, grafikon, dijagram, mapa, fotografija) i/ili pokretnu sliku (npr. animacija, video zapisi, simulacija). Ova definicija je dovoljno opširna da obuhvati različite obrazovne sadržaje i okruženja, kao što su to lekcije u udžbeniku, *online* lekcije s animacijama i naracijom te interaktivne simulacijske igre. Učinkovitost multimedijske poruke ovisi o elementu *instruktivnosti* odnosno prilagodbi i usklađenosti načela oblikovanja poruke s načinom na koji funkcionira ljudski um kako bi se kod pojedinca potaknuli odgovarajući kognitivni procesi u svrhu aktivnog i smislenog usvajanja znanja (Mayer, R. E., 2008). *Instrukcijskim dizajnom*, orijentiranim na primatelja poruke (engl. *learner-centered*) i utemeljenim na empirijski utvrđenim načelima oblikovanja (Mayer 2001, 2005; Mayer, R. E., Moreno, R., 2002), stvara se konstruktivističko multimedijско okruženje u kojem pojedinac iz multimedijскоg prikaza aktivno gradi koherentne verbalne i slikovne mentalne predodžbe i povezuje ih sa već postojećim kognitivnim strukturama ili znanjem pohranjenim u dugoročnoj memoriji.

2.2.2 Ljudski kognitivni sustav za obradu informacija

Kognitivna teorija multimedijскоg usvajanja znanja (engl. *Cognitive theory of multimedia learning*) razvila se na temelju empirijskih istraživanja u posljednjih 25 godina. Ime teorije mijenjalo se kroz godine, ali su njene temeljne pretpostavke ostale iste (tablica 2): dvostruki kanal za obradu informacija, ograničen kapacitet kanala i aktivna obrada informacija (Mayer, R. E., 2001, 2005, 2014a).

Prema konceptu dvostrukog kanala za obradu informacija podrazumijeva se da ljudi imaju odvojene kanale za obradu vizualno/slikovnih i slušno/verbalnih informacija, pri čemu se ljudska svijest može uključiti u samo ograničenu količinu kognitivne obrade informacija u pojedinom kanalu. Razlike između kanala temelje se na načinu prikaza ili formatu sadržaja i osjetilima za primanje informacija. Ako je fokus na načinu prikaza, tada sadržaj može biti prikazan verbalno (govoreni i/ili pisani tekst) ili slikovno (slika, video, animacija, pozadinski zvukovi). Pri tome jedan kanal obrađuje verbalni sadržaj, a drugi kanal obrađuje slikovni sadržaj i neverbalne zvukove (Paivio, A., 1986, prema Mayer, R. E., 2005). Ako je fokus na osjetilnim sustavima za percipiranje sadržaja, kao što su to oči i uši, tada se proučava osjetilo u kojem se vrši inicijalna obrada informacija. Pretpostavka je kako jedan kanal obrađuje vizualno prikazane informacije, a drugi slušno prezentirane informacije. Međutim, kod obrade pisanih riječi i pozadinskih zvukova moguće su među-kanalne obrade istog prikaza. Ako

primatelj poruke izvorno percipira multimedijски prikaz kroz jedan kanal, a ima dovoljno kognitivnih kapaciteta, tada postoji mogućnost da isti prikaz mentalno pretvori u odgovarajuću vizualnu ili zvučnu predodžbu za obradu u drugom kanalu. Na primjer, tekst na zaslonu računala „*kornjača se pomiče za 50 grafičkih jedinica prema naprijed*“, inicijalno se obrađuje u vizualnom kanalu jer se prvotno opaža osjetilnim kanalom vida (oči). Međutim, iskusan primatelj poruke bit će u stanju mentalno pretvoriti vizualnu predodžbu teksta u zvučnu predodžbu koja se potom obrađuje u slušnom kanalu. Shodno tome, slika nekog objekta ili događaja (npr. kornjača) inicijalno se obrađuje u vizualnom kanalu, ali je isto tako moguće mentalno stvoriti pripadajuću zvučnu predodžbu u slušnom kanalu. Suprotno tome, naracija kojom se opisuje tijek nekog događaja (npr. „*kornjača se pomiče za 50 grafičkih jedinica prema naprijed*“) inicijalno se obrađuje u slušnom kanalu jer se prvotno percipira osjetilnim kanalom sluha (uši). Međutim, za istu je zvučnu informaciju moguće stvoriti vizualnu predodžbu kornjače koja se potom obrađuje u vizualnom kanalu. Među-kanalski prikazi istog informacijskog podražaja čine važan dio *teorije dvostrukog kodiranja* (Paivio, A., 1986, prema Mayer, R. E., 2005).

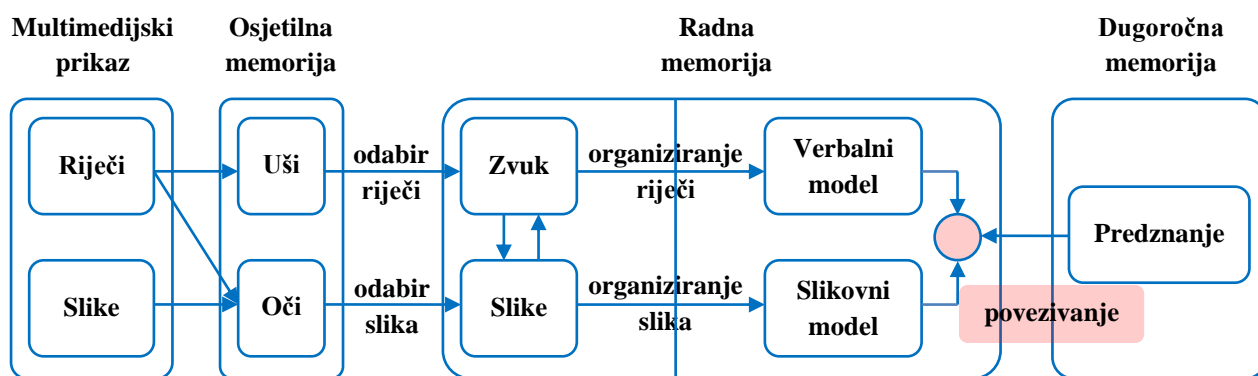
Tablica 2. Temeljni elementi kognitivne teorije multimedijskog usvajanja znanja (Mayer, R. E., 2005, str. 33-36)

| Elementi | Opis | Relevantni izvori |
|----------------------------|--|---|
| Dvostruki kanal | Ljudski sustav za kognitivnu obradu informacija obuhvaća odvojene kanale za obradu vizualno/slikovnih i slušno/verbalnih informacija | Paivio, A (1986, prema Mayer, R. E., 2005); Clark, J. M. i Paivio, A. (1991), Baddeley, A. (1986, 1999, prema Mayer, R. E., 2005), Baddeley, A. (1992) |
| Ograničen kapacitet | Svaki kanal ima ograničeni kapacitet za obradu informacija | Sweller, J., Chandler, P., Tierney, P. i Cooper, M. (1990, prema Mayer, R. E., 2005); Chandler, P. i Sweller, J. (1991); Mousavi, S. Y., Low, R. i Sweller, J. (1995); Sweller, J. i Chandler, P. (1994); Baddeley, A. (1986, 1999, prema Mayer, R. E., 2005) |
| Aktivna obrada | Sustav za aktivnu obradu informacija obuhvaća koordinirani niz kognitivnih procesa u svrhu smislenog usvajanja znanja | Mayer, R. E. (1996, prema Mayer, R. E., 2005); model aktivnih procesa – Mayer, R. E. (2001); generativna teorija učenja – Wittrock, M. C. (1974, 1989, prema Mayer, R. E., 2005) |

Koncept ograničenog kapaciteta kognitivnog sustava za obradu informacija potječe iz psihologije i može se pronaći u istaknutim radovima Baddeleyovog *modela radne memorije*

(Baddeley, A., 1986, 1999, prema Mayer, R. E., 2005; Baddeley, A., 1992), te Chandler i Sweller-ovoj (1991; Sweller, J., 1999, prema Mayer, R. E., 2005) *teoriji kognitivnog opterećenja* (engl. *cognitive load theory*). Kognitivna ograničenost definira količinu informacija koje je moguće obraditi u radnoj memoriji u nekom vremenskom trenutku. Zbog ograničenog kapaciteta primatelj poruke sposoban je zadržati vizualne predodžbe samo određeni broj sekundi. Pri tome, vizualna predodžba odražava dijelove originalnog multimedijskog prikaza, a ne točnu kopiju. Također, primatelj poruke može zadržati samo određeni broj riječi ili zvučnu predodžbu originalnog teksta, a ne izvorni govorni zapis. Zbog ograničenih kapaciteta osjetilne i radne memorije, primatelj poruke je primoran odlučiti kojem dijelu prikaza će posvetiti svoju pažnju i do kojeg stupnja će izgraditi veze između odabranih dijelova mentalnih predodžbi i predznanja. Iz tih razloga sve se više razvijaju metakognitivne strategije za alokaciju, nadgledanje, koordiniranje i prilagođavanje kognitivnih izvora u procesu aktivne obrade informacija (Mayer, R. E., 2005).

Pretpostavka aktivne obrade informacija sugerira kako se smisleno usvajanje znanja odnosno zapamćivanje i razumijevanje sadržaja javlja onda kada je ljudska svijest uključena u odgovarajuće kognitivne procese („odabir riječi“, „odabir slika“, „organiziranje riječi“, „organiziranje slika“, „povezivanje“), radi izgradnje mentalnih modela ili kognitivnih struktura znanja koji obuhvaćaju esencijalne dijelove multimedijskog prikaza i njihove međusobne relacije (Mayer, R. E., Mathias, A. i Wetzell, K., 2002). Na slici 1 prikazan je model *kognitivne teorije multimedijskog usvajanja znanja* (Mayer, R. E., 2005, str. 37, 2014a., str. 52), koji predstavlja ljudski sustav ili kognitivnu strukturu za obradu informacija.



Slika 1. Model kognitivne teorije multimedijskog usvajanja znanja. Izvor: Mayer, R. E. (2005, str. 37, 2014a, str. 52)

Dugogodišnja istraživanja KTMUZ-a orijentirala su se na razvoj multimedijske instruktivne poruke prema kognitivnim načelima oblikovanja (vidi poglavlje 2.2.7), te ispitivanju učinkovitosti upotrebe poruke kao kognitivnog sredstva u konstrukciji znanja (Mayer, R. E., 2001, 2005). Pri tome se instruktivski dizajn primarno fokusirao na razvoj tehnika za minimiziranje sadržajno irelevantnog kognitivnog opterećenja (npr. prostorno povezivanje pisanog teksta i odgovarajućih ilustracija), upravljanje esencijalnim kognitivnim opterećenjem (npr. segmentiranje složenijih sadržaja na manje cjeline) i poticanje sadržajno relevantnog kognitivnog opterećenja radi angažiranja učenika u dublje kognitivne procese u svrhu smislenog usvajanja znanja. Novi evolucijski korak KTMUZ-a započeo je u posljednjih deset godina ugradnjom motivacijskih i metakognitivnih čimbenika, te ispitivanjem njihove uloge u procesu multimedijskog usvajanja znanja, (Mayer, R. E., 2014b; Mayer, R. E. i Estrella, G., 2014; Plass, J. L. i sur., 2014; Leutner, D., 2014; Park, B., Plass, J. L. i Brünken, R., 2014; Park, B., Flowerday, T. i Brünken, R., 2015; Heidig, S., Müller, J. i Reichelt, M., 2015; Liew, T. W. i Tan, S. M., 2016). Prema tim čimbenicima pretpostavlja se kako primatelji poruke imaju želju za ulaganjem truda u kognitivni angažman (motivacija) i sposobni su regulirati vlastite kognitivne procese (metakognicija) (Mayer, R. E., 2014a). Motivacija za učenjem ili *akademska motivacija* odnosi se na unutarnje stanje primatelja poruke koje inicira njegovo ponašanje, te održava i potiče ustrajnost i intenzitet truda u kognitivnom angažmanu (Mayer, R. E., 2011, prema Mayer, R. E., 2014a, str. 65, Mayer, R. E., 2011, 2014b, str. 171). Metakognicija u multimedijskom usvajanju znanja odnosi se na svjesnost učenika i samoreguliranje kognitivnih aktivnosti ili preuzimanju odgovornosti u upravljanju vlastitih kognitivnih procesa za vrijeme učenja (Mayer, R. E., 2011, prema Mayer, R. E., 2014a, str. 65). U skladu s navedenim, buduća istraživanja unutar KTMUZ-a usmjerena su na ispitivanje relevantnih instruktivskih tehnika za poticanje akademske motivacije i metakognicije, razvoju nezavisnih metoda mjerenja ishoda učenja te mjerenja kognitivnog opterećenja, motivacije i upravljanja metakognicije tijekom procesa učenja (Mayer, R. E., 2014a, str. 66).

2.2.3 Memorijska struktura i kognitivni procesi

Memorijska struktura obuhvaća *osjetilnu memoriju* (engl. *sensory memory*), *radnu memoriju* (engl. *working memory*) i *dugoročnu memoriju* (engl. *long-term memory*), (tablica 3).

Osjetilna memorija sastoji se od dva odvojena sustava: *slušne* i *vizualne memorije* i ponaša kao privremeni spremnik različitih informacijskih podražaja detektiranih iz predmetnog okruženja od strane osjetilnih kanala vida i sluha (označeno simbolima strelica na lijevoj strani slike 1), (Baddeley, A. D., 2003, prema Kassim, H., 2011). Funkcija *vizualne osjetilne memorije* je detektirati i zadržati informacije (pisana riječ i slika) koje su opažene očima i trenutno borave u vizualnom kanalu. Funkcija *slušne osjetilne memorije* je detektirati i zadržati informacije (zvuk ili govor) koje su percipirane ušima i trenutno protječu slušnim kanalom. Vizualne informacije se u osjetilnoj memoriji zadržavaju manje od 1 sekunde, a zvučne informacije manje od 3 sekunde. Ako primatelj poruke posveti pažnju vizualnim i/ili zvučnim informacijama one se kroz vizualni i/ili slušni kanal prosljeđuju radnoj memoriji na kognitivnu obradu informacija (Schnotz, W., 2005, prema Mayer, R. E., 2005, str. 56).

Tablica 3. Memorijska struktura prema KTMUZ (Mayer, R. E., 2014, str. 53)

| Vrsta memorije | Opis | Kapacitet | Trajanje | Format |
|---------------------------|---|------------------|-----------------|---|
| Osjetilna memorija | Kratko zadržava osjetilne kopije percipiranih riječi i opaženih slika iz predmetnog okruženja | Neograničen | Vrlo kratko | Vizualne ili slušne osjetilne informacije |
| Radna memorija | Dozvoljava manipulaciju odabranih dijelova vizualnih i zvučnih informacija prosljeđenih iz osjetilne memorije | Ograničen | Kratko | Vizualne i zvučne predodžbe |
| Dugoročna memorija | Trajno pohranjuje organizirano znanje | Neograničen | Trajno | Znanje |

Do sada je opisano i objašnjeno deset različitih modela radne memorije, od kojih je najpoznatiji Baddeleyev model (Miyake, A. i Shah, P., 1999, prema Solaz-Portolés, J. J. i Sanjosé-López, V., 2009). Prema tom modelu obrada i manipulacija informacija u radnoj memoriji pripadaju budnom i aktivnom dijelu ljudske svijesti kroz koju čovjek izvršava kognitivne zadatke, kao što su čitanje, razumijevanje i rasuđivanje (Baddeley, A., 1992; Baddeley, A. i sur., 2009). Radna memorija kao drugi dio kognitivne strukture posjeduje ograničeni kapacitet za obradu informacija (Sweller, J., van Merriënboer, J. J. G. i Paas, F. G. W. C., 1998), te se ponaša kao privremeni spremnik neobrađenih materijala (vizualnih i zvučnih informacija) prosljeđenih iz osjetilne memorije. Prema Miller-u (1956) čovjek ima

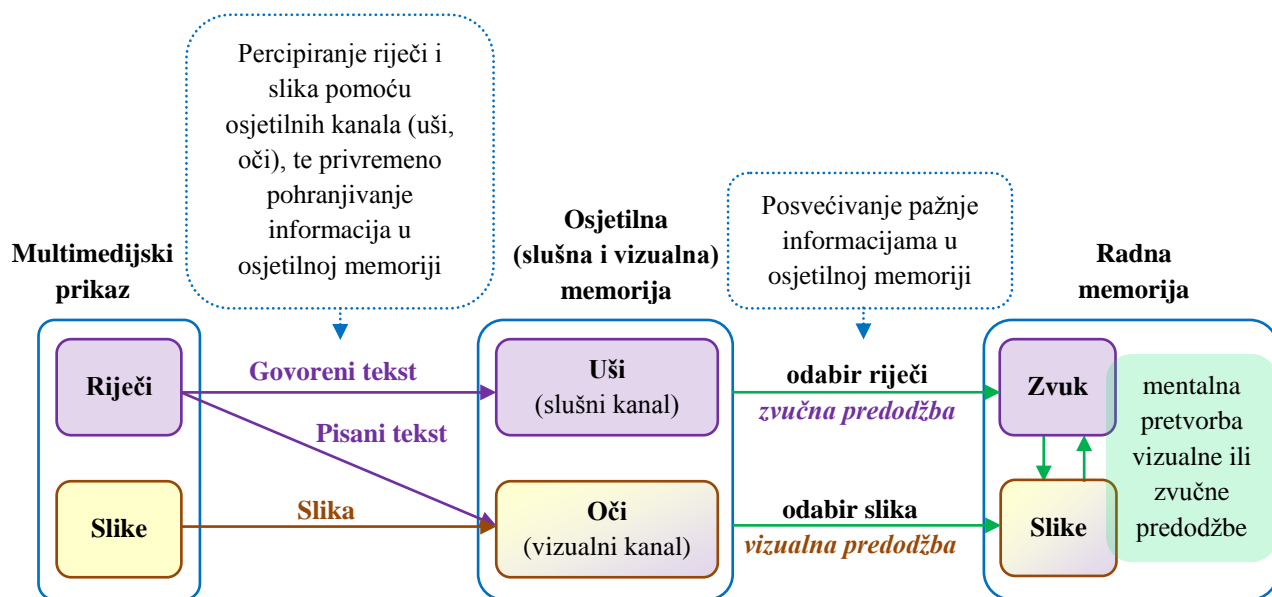
sposobnost u radnoj memoriji istovremeno zadržati oko 7 (± 2) dijelova informacija (engl. *chunks*) (Miller, G. A., 1956), a manipulirati sa 2-3 elementa za vrijeme obrade informacija (Sweller, J., van Merriënboer, J. J. G. i Paas, F. G. W. C., 1998). Pri tome, vijek trajanja novopristigle informacije u radnu memoriju, koja se ne ponovi više puta, iznosi 15 do 30 sekundi, nakon čega dolazi do njenog raspadanja (Driscoll, M. P., 2005, prema Artino, A. R., Jr., 2008). Implikacije dvostrukog kanala za obradu informacija očituju se u mogućnosti proširenja ograničenog kapaciteta radne memorije istovremenom upotrebom vizualnog i slušnog kanala, umjesto samo jednog (Sweller, J., van Merriënboer, J. J. G. i Paas, F. G. W. C., 1998).

Proces konstrukcije znanja u radnoj memoriji opisuje se izgradnjom verbalnih i slikovnih mentalnih modela, pri čemu obrada informacija obuhvaća niz od 5 kognitivnih procesa (slika 1):

- „*odabir relevantnih riječi iz prikazanog teksta ili naracije*“,
- „*odabir relevantnih slika iz prikazanih ilustracija*“,
- „*organiziranje odabranih riječi ili dijelova zvučne predodžbe u verbalni mentalni model*“,
- „*organiziranje odabranih slika ili dijelova vizualne predodžbe u slikovni mentalni model*“,
- „*povezivanje svih dijelova verbalnog i slikovnog modela s predznanjem*“.

Prema slici 2, prvi *kognitivni proces* definira se kao „*odabir relevantnih riječi iz prikazanog teksta ili naracije*“. Pisani tekst kojeg su opazile oči na zaslonu računala prikazan je simbolom strelice „Riječi-Oči“, a naracija ili govoreni tekst kojeg su percipirale uši prikazan je simbolom strelice „Riječi-Uši“. Pisani tekst se inicijalno obrađuje u vizualnom kanalu, a govoreni tekst u slušnom kanalu. Percipirani tekst i govor se kratko vrijeme zadržavaju u njima pripadajućim osjetilnim memorijama, vizualnoj i slušnoj. Ako primatelj poruke svjesno posveti pažnju tekstu ili govoru kako bi odabrao njemu važne dijelove iz multimedijskog prikaza tada započinje aktivna obrada informacija, gdje se vizualne i zvučne informacije iz osjetilne memorije prosljeđuju radnoj memoriji pri čemu dolazi do stvaranja *vizualne predodžbe* za opaženi tekst ili *zvučne predodžbe* za percipirani govor. Svjesno posvećena pažnja važnim dijelovima prikaza čini primatelja poruke aktivnim procesorom koji traži smisao u prikazanom sadržaju. Uz dovoljno dostupnu količinu kognitivnog kapaciteta primatelj poruke će biti sposoban mentalno pretvoriti *vizualnu predodžbu* opaženog teksta u

zvučnu predodžbu odnosno mentalno artikulirati pisani tekst (prikazano simbolom strelice „Slike-Zvuk“). Također, moguća je i mentalna pretvorba zvuka (npr. izgovorena riječ *kornjača*) u *vizualnu predodžbu* (npr. predodžba *kornjače*), (prikazano simbolom strelice „Zvuk-Slike“), što znači da kada čovjek čuje riječ *kornjača* on istovremeno stvara mentalnu sliku *kornjače*. Prvi kognitivni proces ograničen je kapacitetom kognitivnog sustava ili količinom informacija koju je moguće obraditi u radnoj memoriji.



Slika 2. Kognitivni procesi – „odabir relevantnih riječi iz prikazanog teksta ili govora“ i odabir „relevantnih slika iz prikazanih ilustracija“

Drugi kognitivni proces (slika 2) definira se kao „odabir relevantnih slika iz prikazanih ilustracija“. Sliku koju su opazile oči prikazana je simbolom strelice „Slike-Oči“. Opažena statična slika ili pokretna slika (animacija) kratko se vrijeme zadržava u vizualnoj osjetilnoj memoriji. Ako primatelj poruke svjesno posveti pažnju slici i odabere njemu važne dijelove iz *multimedijskog* prikaza tada započinje aktivna obrada informacija, gdje se vizualne informacije iz osjetilne memorije prosljeđuju radnoj memoriji pri čemu dolazi do stvaranja *vizualne predodžbe* opažene slike. Uz dovoljno dostupnu količinu kognitivnog kapaciteta primatelj poruke će biti u stanju mentalno pretvoriti *vizualnu predodžbu* (npr. mentalna slika *kornjače*) u *zvučnu predodžbu* (npr. zvuk riječi *kornjača*), što znači da kada čovjek opazi sliku *kornjače* on mentalno čuje riječ *kornjača* (prikazano simbolom strelice „Slike-Zvuk“). Drugi kognitivni proces ograničen je kapacitetom kognitivnog sustava ili količinom informacija koju je moguće obraditi u radnoj memoriji.

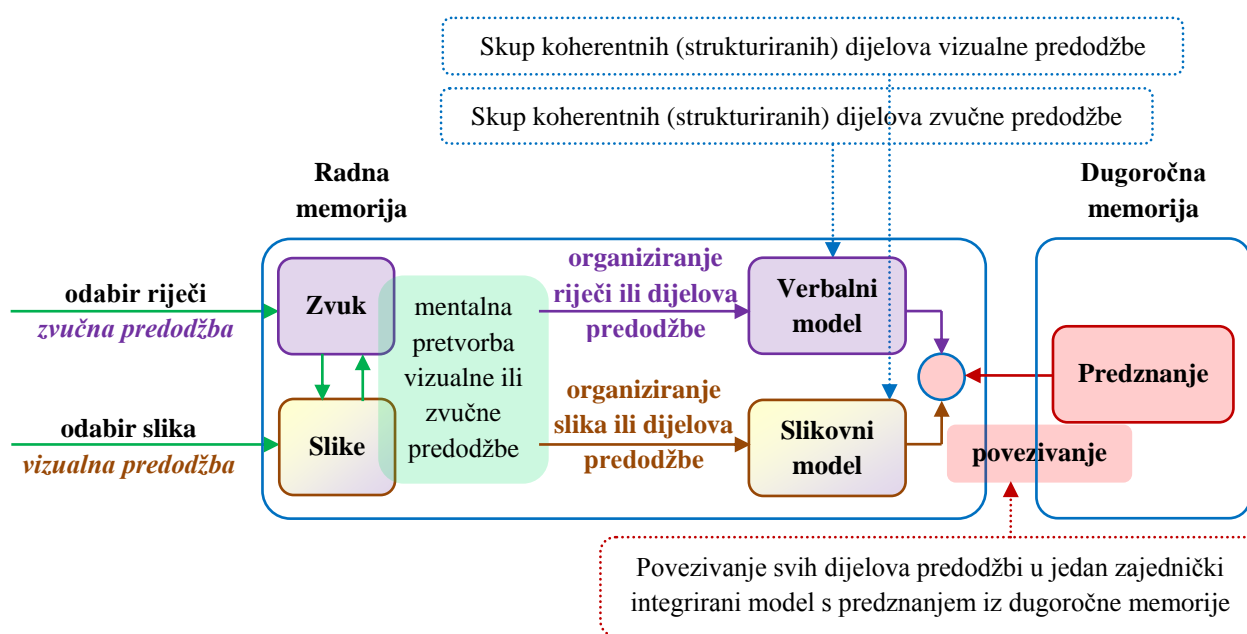
U trećem kognitivnom procesu (slika 3) u radnoj memoriji dolazi do *organiziranja odabranih riječi iz multimedijskog prikaza ili dijelova zvučne predodžbe u verbalni mentalni model*. Primatelj poruke gradi mentalne (unutarnje) veze između dijelova zvučne predodžbe te ih organizira u koherentnu (strukturiranu) predodžbu odabranih riječi ili verbalni mentalni model (strukturu znanja). Kao i u prethodnim procesima, postoji kognitivno ograničenje u izgradnji svih mogućih veza stoga je primatelj poruke fokusiran na izgradnju jednostavne verbalne strukture. Proces organizacije odabranih riječi nije proizvoljan već reflektira uloženi trud primatelja poruke u izgradnji verbalne strukture koja za njega ima smisla, kao što je izgradnja kognitivnog niza uzročno-posljedičnih veza između odabranih verbalnih komponenti koje opisuju određeni proces ili fenomen (npr. opis formiranja munje).

U četvrtom kognitivnom procesu (slika 3) u radnoj memoriji dolazi do *organiziranja odabranih slika iz multimedijskog prikaza ili dijelova vizualne predodžbe u slikovni mentalni model*. Primatelj poruke gradi mentalne (unutarnje) veze između dijelova vizualne predodžbe te ih organizira u koherentnu (strukturiranu) predodžbu odabranih slika ili slikovni mentalni model (strukturu znanja). Kao i u prethodnim procesima, postoji kognitivno ograničenje u izgradnji svih mogućih veza stoga je primatelj poruke fokusiran na izgradnju jednostavne slikovne strukture. Proces organizacije odabranih slika nije proizvoljan već reflektira uloženi trud primatelja poruke u izgradnji slikovne strukture koja za njega ima smisla, kao što je izgradnja kognitivnog niza uzročno-posljedičnih veza između odabranih slika koje opisuju određeni proces ili fenomen (npr. opis rada ljudskog srca i krvotoka).

Posljednji i krucijalni kognitivni proces (slika 3) u multimedijском usvajanju znanja je izgradnja referentnih mentalnih veza između svih dijelova zvučne i vizualne predodžbe (verbalnog i slikovnog modela) i njihovih međusobnih relacija u jedan zajednički *integrirani mentalni model*. To se istovremeno odvija u vizualnoj i verbalnoj radnoj memoriji uz njihovu međusobnu koordinaciju. Proces završava povezivanjem integriranog modela s predznanjem pohranjenim u dugoročnoj memoriji. Ovo je ekstremno zahtijevan proces i iziskuje učinkovito korištenje kognitivnih kapaciteta. Želi li se postići smisljeno usvajanje znanja primatelj poruke se mora fokusirati na osnovnu verbalnu i slikovnu strukturu, pri čemu mu predznanje pomaže u povezivanju svih dijelova predodžbi u integrirani model.

Dugoročna memorija ima neograničeni kapacitet i mogućnost trajnog zadržavanja informacija. Prema *teoriji shema* (engl. *schema theory*), znanje se organizira i pohranjuje u

dugoročnu memoriju u formi kognitivnih struktura zvanih *shema* (engl. *schema*), koje ujedno sadrže i informacije o upotrebi tog znanja (Rumelhart, D. E., 1980, str. 34; Détiennne, F., 1990, str. 206). *Sheme* (engl. *schemas*) se promatraju kao mentalne strukture podataka za prikaz generičkog konceptualnog znanja (Rumelhart, D. E., 1980, str. 34; Détiennne, F., 1990, str. 206; Sorva, J., 2012). Postojeće *sheme* u dugoročnoj memoriji predstavljaju centralni izvršni organ koji kontrolira i usmjeruje kognitivne procese u radnoj memoriji, određuju kada i kako će se neke aktivnosti izvršiti te način na koji će se novo proživljena iskustva integrirati u mentalne predodžbe (mentalni model) (Mayer, R. E., 1992a, prema Solaz-Portolés, J. J. i Sanjosé-López, V., 2009; Sorva, J., 2012). Potpuni skup *shema* koje čovjek ima na raspolaganju, za rasuđivanje i interpretiranje objekta ili događaja, čini njegovu osobnu teoriju prirode stvarnosti odnosno unutarnji model proživljenog iskustva ili situacije s kojom se suočava ili dolazi u doticaj (Rumelhart, D. E., 1980, str. 37; Sorva, J., 2012). Ako *sheme* nisu prisutne u dugoročnoj memoriji čovjek je sposoban donositi samo nasumične odluke u susretu s novim informacijama zbog nedostatka predznanja koje bi ga usmjerilo u procesu obrade informacija (Mayer, R. E., 2005).



Slika 3. Kognitivni procesi – „organiziranje odabranih riječi ili dijelova zvučne predodžbe u verbalni mentalni model“, „organiziranje odabranih slika ili dijelova vizualne predodžbe u slikovni mentalni model“ i „povezivanje svih dijelova predodžbi s predznanjem“

Teorija shema smatra se pretečom modernoj kognitivnoj psihologiji (Détiennne, F., 1990). Istaknula se među teorijama učenja unutar psiholoških i edukacijskih istraživačkih

zajednica 70-tih godina 20-tog stoljeća. Njeni temelji pripisuju se knjizi *Remembering: A Study in Experimental and Social Psychology*, istaknutog britanskog eksperimentalnog psihologa Frederica Charlesa Bartletta (1932), čije su ideje revitalizirali istraživači Minsky (1974) uvođenjem određenih vrsta *shema* ili „okvira“ (engl. *frames*) na području umjetne inteligencije u svojim nastojanjima modeliranja ljudske kognitivne arhitekture, te Schank i Abelson (1977, prema Ormerod, T., 1990, str. 67), identificiranjem određene vrste *sheme* poznate kao „skripta“ (engl. *script*) ili niz apstraktnih aktivnosti koje se pojavljuju u sličnim ili već poznatim situacijama, gdje se proces zaključivanja temelji na predznanju pojedinca. Uz skripte, Schank i Abelson (1977) su identificirali i „planove“ (engl. *plans*) koji opisuju izvođenje aktivnosti potrebnih za razumijevanje novih ili nestereotipnih situacija ili događaja, gdje se proces zaključivanja temelji na postignutim ciljevima u nedostatku znanja za određenu aktivnost. Jean Piaget (1952, str 237) predložio je esencijalnu ideju *sheme* kao potpuno objedinjeni međukoordinirani skup fizičkih pokreta i kognitivnih funkcija koji odgovaraju na svako percipirano i proživljeno iskustvo koje je moguće povezati s dotičnom *shemom*. Pri tome, *sheme* karakteriziraju dvije funkcije: asimilacija i akomodacija. Prema asimilaciji novo iskustvo se prilagođava i ugrađuje u već postojeću *shemu*. Međutim, ako su iskustva presložena ili previše različita od postojećih *shema*, proces asimilacije bit će neuspješan i tada nastupa akomodacija ili promjena i usklađivanje postojećih kognitivnih struktura s novim iskustvima.

Proces konstrukcije *shema* sastoji se od dvije glavne funkcije koje je važno uzeti u obzir prilikom oblikovanja instrukcijskih materijala za učenje radi njihova usklađivanja s kognitivnom arhitekturom čovjeka čime se potiče konstrukcija znanja: (1) organizacija i pohrana znanja, (2) smanjenje kognitivnog opterećenja radne memorije i povećanje njenog kapaciteta. Svaka se *shema* promatra kao pojedinačni element koji se razlikuje od drugih elemenata po svojoj razini složenosti. *Sheme* niže instance sadrže jedan element. *Sheme* više instance, koje su nastale kroz duži period procesa učenja, sadrže više elemenata niže instance u međusobnoj interakciji. Pri tome, elementi uključeni u stjecanje *shema* više instance ponašaju se kao *sheme* niže instance (Sweller, J., 1994, str. 306). Na primjer, dijete rane dobi u procesu učenja čitanja konstruira *sheme* niže instance za prepoznavanje abecednih slova koja se mogu pojaviti u nebrojenom nizu oblika (vidljivo prema rukopisu). Te *sheme* postaju elementi koji tvore riječi i za koje je potrebno steći nove *sheme* više instance. One potom djeluju kao elementi u frazama i rečenicama (Sweller, J. i Chandler, P., 1994, str. 190). Prilikom obrade *shema* u radnoj memoriji one se pojavljuju kao pojedinačni elementi bez obzira na njihov stupanj informacijske složenosti (Baddeley, A. D., 2003, prema Kassim, H.,

2011). Odnosno, iako radna memorija u određenom trenutku može zadržati i obraditi samo određeni broj elemenata; njihova veličina, složenost i profinjenost nisu ograničeni (Sweller, J., van Merriënboer, J. J. G. i Paas, F. G. W. C., 1998, str. 256). Na taj se način smanjuje kognitivno opterećenje radne memorije i povećava kapacitet obrade informacija.

Drugi važan mehanizam učenja, koji uz konstrukciju *shema* koristi znanje pohranjeno u dugoročnoj memoriji kako bi se smanjilo kognitivno opterećenje radne memorije, jest proces automatizacije *shema* (Sweller, J. i Chandler, P., 1994, str. 187). U tom se procesu informacije u radnoj memoriji obrađuju automatski, s minimalno uloženog svjesnog truda odnosno s minimalnim opterećenjem radne memorije (Sweller, J., van Merriënboer, J. J. G. i Paas, F. G. W. C., 1998, str. 256). Konstruirane sheme postaju automatizirane nakon dugogodišnje prakse i iskustva te variraju po stupnju automatiziranosti (van Merriënboer, J. J. G., Sweller, J., 2005, prema Artino, A. R., Jr., 2008). Na primjer, odrastao čovjek u stanju je čitati tekst bez svjesne obrade pojedinačnih slova, jer su procesi uključeni u čitanje postali automatizirani još u njegovu djetinjstvu. Nasuprot tome, dijete rane dobi koje uči čitati mora svjesno obraditi svako pojedinačno slovo. S druge strane, ako se čovjek suoči s potpuno novim zadatkom možda ga neće biti u stanju izvršiti sve dok ne usvoji i automatizira potrebne vještine, jer bez automatizacije postoji mogućnost da neće imati dovoljno kapaciteta radne memorije za proces učenja i izvršavanje tog zadatka (van Merriënboer, J. J. G. i Sweller, J., 2005, prema Artino, A. R., Jr., 2008). Smatra se kako su ljudske intelektualne sposobnosti, znanja i vještine određeni sposobnošću konstruiranja većeg broja *shema* više instance s većim stupnjevima automatizacije (Sweller, J., van Merriënboer, J. J. G. i Paas, F. G. W. C., 1998).

2.2.4 Mentalni modeli

Mnogi su istraživači istaknuli kako kognitivne strukture za prikaz generičkog konceptualnog znanja u *shemama* nisu dovoljne za razumijevane ljudskih mentalnih aktivnosti i ponašanja u radu i susretu s nepoznatim objektima i sustavima (Sorva, J., 2012). Dok su *sheme* nefleksibilne generičke strukture znanja pohranjene u dugoročnoj memoriji koje pružaju „*prediktivno znanje za visoko regularne i rutinske situacije*“ (Holland, J. H. i sur., 1986, str. 13, prema Jones, N. A. i sur., 2011), mentalni modeli su fleksibilne i specifične strukture znanja koje kombiniraju višestruke *sheme* kako bi predočili ili simulirali nepoznate situacije (Holland, J. H. i sur., 1986, prema Jones, N. A. i sur., 2011). Stoga je u teoriji shema primarni fokus na izgradnji ljudske mogućnosti interpretiranja i ophođenja s novim,

nesterotipnim i složenim situacijama, a u teoriji mentalnih modela na ljudskoj sposobnosti upravljanja novim situacijama i kauzalnim sustavima (Sorva, J., 2012).

2.2.4.1 Definicije mentalnih modela

Koncept mentalnog modela prvi je postulirao psiholog i fiziolog Kenneth Craik u svom radu *The Nature of Explanation* (1943, prema Staggers, N. i Norcio, A. F., 1993; Johnson-Laird, P. N., 1980). Craik je smatrao kako ljudi mentalno simuliraju događaje i ponašanja iz vanjskog svijeta te ih pretvaraju u unutarnje modele malog opsega (engl. *small-scale model*) koje koriste za „predviđanje događaja, proces rasuđivanja i formiranje objašnjenja“ (Wilson, R. A. i Keil, F. C., 1999, str. 525), identificiranjem sličnosti između vanjskih događaja i unutarnjih predodžbi (Schwamb, K. B., 1990, str. 4). Craik je naglašavao strukturalne aspekte modela, ne ulazeći u konstrukciju, modifikacije ili sadržaj modela (Staggers, N. i Norcio, A. F., 1993). Od Craikove prvotne zamisli do danas definicija *mentalnog modela* ostala je nejasna s raznolikom upotrebom termina u različitim područjima istraživanja (Guan, Y.-H., 2002). Rapp (2005, str. 44-45) navodi razloge zbog kojih je mentalne modele teško jednoznačno i konkretno definirati: (1) „apstraktni koncepti koji se ne mogu izravno promatrati, već se o njima donose tvrdnje kroz logičke asocijacije s vidljivim ponašanjem“; (2) „čisto apstraktni opisi memorije“ i „dinamičke predodžbe koje se mijenjaju kroz vrijeme“; (3) definirani na različite načine kroz različita istraživačka područja (razvojna psihologija, računalno programiranje i dr.), između kojih u većini slučajeva nije bilo mnogo interakcije; (4) ljudi se u procesu razumijevanja često oslanjaju na netočne i neispravne mentalne modele što dovodi do pogrešnih zaključaka.

Brojni autori iz raznih istraživačkih područja iznijeli su određene tvrdnje u vezi mentalnih modela:

- „konceptualne organizacije informacija u memoriji“ (Rapp, D. N., 2005, str. 45);
- „osobne, unutarnje predodžbe vanjske stvarnosti koje ljudi koriste u interakciji sa svijetom oko sebe. Konstruirane od strane pojedinca na temelju osobnih životnih iskustava, percepcija i shvaćanja svijeta oko sebe. Koriste se za rasuđivanje i donošenje odluka te mogu biti osnova individualnih ponašanja“ (Jones, N. A. i sur., 2011, str. 1);
- „internalizirane, organizirane strukture koje se koriste za rješavanje problema...kodarane s obzirom na prostorne, vremenske i uzročne odnose

između koncepata. Moguće ih je pokretati radi simulacije koncepta kako bi se procijenili alternativni stavovi i razmotrile mogućnosti koje nisu lako dostupne ili očite“ (Rapp, D. N., 2005, str. 46).

- *„nisu točne unutarnje replike vanjskih informacija, već su prilično fragmentirani, nepotpuni dijelovi informacija koje se dohvaćaju kao funkcija korisnikovog zadatka ili cilja“ (Tversky, 1993, prema Rapp, D. N., 2005, str. 46).*
- *„predstavljaju necjelovite predodžbe vanjske stvarnosti“ (ljudska sposobnost predočavanja svijeta je ograničena i individualna) i „nedosljedne predodžbe, jer su sadržajno ovisni i mogu se mijenjati ovisno o situaciji u kojoj se primjenjuju“ (Jones, N. A. i sur., 2011, str. 1).*
- *„nije ih moguće izravno mjeriti“ (Jones, N. A. i sur., 2011, str. 2). Pokazalo se kako samo indirektni dokazi potvrđuju postojanje teorije mentalnih modela, bilo promatranjem razlika u sposobnostima rješavanja problema između početnika i stručnjaka iz određene domene znanja, bilo uspoređivanjem ostvarenih postignuća (Staggers, N. i Norcio, A. F., 1993).*
- *„često nisu produkt svjesnog rasuđivanja, mogu biti formirani intuitivno i poprilično nesvjesno“ (Sorva, J., 2012, str. 54).*

Ranih 80-tih koncept *mentalnog modela* dobio je veliku pažnju na području kognitivne psihologije čija su istraživanja iznjedrila dvije glavne struje proučavanja i tumačenja mentalnih modela, koje su temeljno mogu pripisati Craikovoj prvotnoj notaciji *„modela stvarnosti“* (Sorva, J., 2012):

- (1) Logički mentalni modeli – prema teorijskom pristupu Johnson-Lairda (1983, prema Ma, L., 2007) koji je nastojao ponuditi ujedinjenu i objašnjavajuću teoriju kognitivnih fenomena, kao što su deduktivno rasuđivanje i razumijevanje diskursa, upotrebom teorije mentalnih modela (Greca, I. M. i Moreira, M. A., 2000, str. 2). Mentalne modele promatrao je kao analogijske prikaze stvarnosti (Greca, I. M. i Moreira, M. A., 2000, str. 3) i situacijski određene predodžbe ili konstrukte koje ljudi kreiraju u svojoj radnoj memoriji kako bi si pomogli u procesu rasuđivanja oko logičkih problema (Sorva, J., 2012). Za njega, mentalni modeli su radni modeli situacija ili događaja i putem mentalne manipulacije tih modela ljudi mogu razumjeti ili objasniti fenomene (Greca, I. M. i Moreira, M. A., 2000, str. 4). Pri

tome, strukturalna sličnost mentalnog modela i fenomena kojeg taj model predočava je nužan uvjet za proces donošenja odgovarajućih zaključaka o fenomenu. Također, mentalni model ne treba biti kompleksan kao i sam fenomen, već puno jednostavniji (Ma, L., 2007, str 16). Johnson-Laird navodi *rekurzivnost* kao važnu karakteristiku prema kojoj se mentalni modeli karakteriziraju kao dinamične predodžbe, nikada cjelovite i koje se postupno uvećavaju i unaprjeđuju kako se nove informacije ugrađuju u njih. Isti se proces odvija u razumijevanju diskursa, gdje se u procesu razgovora novi elementi ugrađuju u originalnu ideju te ju modificiraju. Rekurzivni proces ovisi o znanju i vještini pojedinca te svrsi konstruiranja mentalnog modela (Greca, I. M. i Moreira, M. A., 2000, str. 4-5).

- (2) Kauzalni mentalni modeli – prema instrukcijskom pristupu istraživača Gentner i Stevens (1983, prema Ma, L., 2007), koji su postavili fokus na znanje o fizičkim fenomenima, osobito mehaničkih i tehnoloških uređaja koje ljudi razvijaju (Greca, I. M. i Moreira, M. A., 2000, str. 2). Ideja mentalnog modela koja čini temelj instrukcijskom pristupu je *„vrsta prikaza znanja koje je implicitno, nepotpuno, neprecizno, nekoherentno s normativnim znanjem u raznim domenama, ali je korisno, jer se pokazuje kao moćan objašnjavajući i prediktivni alat u interakciji subjekta s vanjskim svijetom, i ovisan izvor znanja budući da proizlazi iz subjektivnih perceptivnih i manipulativnih iskustava s vanjskim svijetom“* (Barquero, B., 1995, str. 12, prema Greca, I. M. i Moreira, M. A., 2000, str. 3). Kauzalni mentalni modeli su mentalne predodžbe koje se koriste u procesu rasuđivanja kao podrška ljudima i temelje se na znanju iz određene domene pohranjenom u dugoročnoj memoriji. Koriste se u procesu rasuđivanja u domeni fizičkih sustava i mehanizama, kao što su prostorne predodžbe, ljudsko-računalna interakcija, ekologija i razvoj astronomskog znanja (Gentner, D. i Stevens A., 1983, prema Markman, A. B. i Gentner, D., 2001, str. 229).

Jedan od najranijih radova na području ljudsko-računalne interakcije napisao je Norman, D. A. (1983, prema Ma, L., 2007, str. 17), istaknuvši niz važnih koncepata koje treba uzeti u obzir prilikom istraživanja kauzalnih mentalnih modela računalnih sustava. Terminologiju tih koncepata ili različitih vrsta modela naknadno su uredili Turner i Bélanger (1996, prema Sorva, J., 2012, str. 58):

- Ciljani sustav (engl. *target system*) – sustav koji je oblikovan, koji se upotrebljava i o kojem se uči (interakcija s korisnikom), kao što su programska (softver) i sklopovska (hardver) podrška (Ma, L., 2007, str. 17);
- Mentalni model ciljanog sustava formiran od strane dizajnera (engl. *design model*);
- Mentalni model dizajnera (stereotipni) o korisniku sustava (engl. *user model*);
- Slika sustava (engl. *system image*) – dijelovi ciljanog sustava koji su vidljivi korisniku, razni prikazi (sučelja, dijaloški okviri, ikone), kontrole i pomoćne datoteke. Predstavlja implementaciju konceptualnog modela koji se sastoji od aspekata ciljanog sustava (Ma, L., 2007, str. 17), i svojevrsnu impresiju kojeg sustav ostavlja na korisniku (Staggers, N. i Norcio, A. F., 1993, str. 588);
- Korisnikov mentalni model (engl. *user's model*) – unutarnji mentalni model ili predodžba korisnika ciljanog sustava koji se oblikuje kao rezultat interakcije korisnika s ciljanim sustavom (Ma, L., 2007, str. 17);
- Konceptualni model (engl. *conceptual model*) – sustav koji predstavlja objašnjenje rada ciljanog sustava (engl. *how-it-works*) i koji je oblikovan od strane dizajnera, učitelja, znanstvenika i inženjera kao točne, dosljedne i cjelovite predodžbe ciljanog sustava (Ma, L., 2007, str. 17). Može i ne mora biti dosljedan slici sustava.

2.2.4.2 Karakteristike mentalnih modela

Prva istraživanja mentalnih modela bila su na području obrade teksta i ručnih kalkulatora (Staggers, N. i Norcio, A. F., 1993, str. 590) i određene karakteristike mentalnih modela identificirane su promatranjem ljudsko-računalne interakcije (Norman, D. A., 1983, prema Sorva, J., 2012, str. 53-54):

- održavaju uvjerenja koja ljudi posjeduju u vezi s korištenim sustavima i vlastitim ograničenjima (stupanj nesigurnosti u različitim aspektima znanja);
- pružaju pojednostavljena objašnjenja složenih fenomena;
- *necjeloviti su i nestabilni*, jer ljudi zaboravljaju detalje njihovih modela ili ih odbacuju (Norman, D. A., 1983, prema Greca, I. M. i Moreira, M. A., 2000), osobito kada duže vrijeme nisu u doticaju s ciljanim sustavom (Norman, D. A., 1983, prema Ma, L., 2007, str. 19);

- *neznanstveni su i neprecizni*, jer reflektiraju ljudska vjerovanja o prikazanom sustavu odnosno često se temelje na nagađanjima, naivnim pretpostavkama i *predrasudama* koja ljudi podržavaju iako znaju da su pogrešna i nepotrebna;
- *oskudni su na mnogo načina*, jer obuhvaćaju kontradiktorne, pogrešne i nepotrebne koncepte; ljudi su spremni fizički raditi više u zamjenu za smanjenu mentalnu aktivnost (Norman, D. A., 1983, str. 8, prema Staggers, N. i Norcio, A. F., 1993, str. 595-596);
- *nedostaju im čvrste granice* odnosno nemaju jasno definirane granice – ljudima često nije jasno koje aspekte ili dijelove sustava njihov mentalni model pokriva (čak i kod cjelovitih i točnih modela). Ljudi vrlo često zamjenjuju ili kombiniraju mentalne modele sličnih sustava te mogu posjedovati višestruke nedosljedne modele unutar jedne domene ili paralelne (moguće kontradiktorne) modele istih dijelova sustava. Ti paralelni modeli mogu međusobno djelovati na različitim razinama apstrakcije (jedan model opisuje fizičke aspekte sustava, a drugi funkcijsku svrhu).
- *evoluiraju kroz vrijeme* kako ljudi stupaju u interakciju sa (ciljanim) sustavima i modificiraju svoje modele kako bi postigli uspješne rezultate;
- *podložni su promjeni* u bilo koje vrijeme;
- *može ih se 'pokretati'* radi mentalne simulacije i predviđanja rada sustava (uz poznate inicijalne uvjete ili stanja sustava), što ih čini „izvodljivim“ kauzalnim modelima sustava ili mehanizma kojeg predočavaju (Greca, I. M. i Moreira, M. A., 2000, str. 3). Pri tome, ljudska sposobnost pokretanja modela ili mentalne simulacije je ograničena, jer se izvodi u radnoj memoriji koja je ograničenog kapaciteta.

2.2.4.3 Konceptualni modeli

Konceptualni model oblikovan od strane dizajnera, učitelja, znanstvenika i inženjera predstavlja objašnjenje strukture i rada nekog sustava, a može biti u formi jednostavne metafore ili složenijeg objašnjenja, te dio samog sustava (pridodan dokumentaciji) ili prikazan odvojeno od sustava (Sorva, J., 2012, str. 58). Svrha konceptualnog modela je prikazati djelomični ili cjeloviti sadržaj mentalnog modela ciljanog sustava na pedagoško motivirajući

način kako bi se olakšala izgradnja održivog mentalnog modela korisnika (Sorva, J., 2012, str. 58).

Konceptualni model se kao alat za razumijevanje ili poučavanje ciljanog sustava postavlja između korisnika i ciljanog sustava (Norman, D. A., 1983, prema Ma, L., 2007, str. 17), gdje se održivost korisnikovog mentalnog modela postiže točnošću i dosljednošću konceptualnog sustava s ciljanim sustavom (Ma, L., 2007, str. 18). Međutim, korisnikov mentalni model u većini slučajeva značajno odstupa od konceptualnog ili kognitivnog modela zbog raznih faktora, kao što su predznanje i sposobnosti korisnika te različita uvjerenja oko svrhe i funkcije sustava (Jonassen, D. H., 1995, str. 183). Kada korisnici prime informaciju putem konceptualnog modela imaju tri mogućnosti (Greca, I. M. i Moreira, M. A., 2000, str. 8): (1) interpretirati informacije u skladu sa postojećim znanjem što često dovodi do stvaranja hibridnih mentalnih modela; (2) zapamtiti informacije u formi nepovezanih listi kroz unutarnje propozicijske predodžbe kako bi uspješno prošli provjeru znanja; (3) stvoriti vlastiti mentalni model dosljedan prikazanim informacijama konceptualnog modela. U znanstvenoj edukaciji pokazalo se kako učitelji nisu u stanju osposobiti učenike u uspješnom stvaranju mentalnih modela zbog: (1) nedostatka predznanja pomoću kojeg bi učenici interpretirali prikazane konceptualne modele; (2) učenikovog pogrešnog shvaćanja kako je konceptualni model pojednostavljena i idealizirana predodžba fenomena ili situacije, bez uvida u stvarni fenomen ili situaciju (Greca, I. M. i Moreira, M. A., 2000, str. 6).

Prema Normanu (1983, prema Greca, I. M. i Moreira, M. A., 2000, str. 5) konceptualni modeli su precizni i cjeloviti vanjski prikazi dosljedni znanstveno prihvaćenom znanju. To su „*pojednostavljeni prikazi realnih objekata, fenomena ili situacija*“ koje se mogu realizirati kao matematičke formulacije (npr. model jezgre iz nuklearne fizike), analogije (npr. analogija između Rutherfordovog atoma i solarnog sustava) ili materijalni artefakti (npr. artefakt koji prikazuje način rada pumpe za vodu) (Greca, I. M. i Moreira, M. A., 2000, str. 5).

Mayer (1989a) je razvio instrukcijsku metodu upotrebom konceptualnih modela kako bi pomogao studentima (početnici u određenoj domeni znanja) u razumijevanju znanstvenih koncepata i potaknuo kognitivne procese koji su odgovorni za smisleno usvajanje ili konstrukciju znanja. Konceptualni model je definirao „*kao riječi i/ili dijagrame čija je svrha pomoći u izgradnji mentalnih modela sustava kojeg studenti proučavaju i trebaju usvojiti*“ (Mayer, R. E., 1989a, str. 43). Pri tome, konceptualni model predstavlja tekstualne i slikovne prikaze koji objašnjavaju rad sustava (engl. *explanative*), te ističe glavne komponente, stanja, aktivnosti i međusobne relacije unutar prikazanog sustava.

2.2.5 Kognitivna opterećenja i instrukcijski dizajn

Teorija kognitivnog opterećenja (engl. *cognitive load theory*) (Sweller, J. i Chandler, P., 1994) proučava odnose između ljudske kognitivne arhitekture, formacije *shema* i strukture informacija te predstavlja jedan od važnijih ogranaka teorije *shema*. Za vrijeme aktivne obrade informacija u radnoj memoriji mogu se pojaviti tri vrste kognitivnih procesa koji pridonose kognitivnom opterećenju (tablica 4): esencijalno (engl. *intrinsic or essential*), sadržajno irelevantno (engl. *extraneous or ineffective*) i sadržajno relevantno (engl. *germane or generative*) opterećenje (Sweller, J., van Merriënboer, J. J. G. i Paas, F. G. W. C., 1998; Mayer, R. E., 2001; DeLeeuw, K. E. i Mayer, R. E., 2008). Teorija implicira kako je kognitivno opterećenje radne memorije glavna prepreka konstruktivističkom usvajanju znanja iz multimedijских prikaza. Konstruktivističko učenje ostvaruje se kada je primatelj poruke sposoban simultano zadržati referentne veze između vizualnih i zvučnih predodžbi u radnoj memoriji te izgraditi odgovarajući mentalni model. Ako je sustav za obradu informacija preopterećen tada nije moguće uspostaviti veze čime se blokira i zaustavlja proces konstrukcije znanja.

Tablica 4. Tri vrste kognitivnih opterećenja (DeLeeuw, K. E. i Mayer, R. E., 2008; Paas, F., Renkl, A. i Sweller, J., 2003)

| Kognitivno opterećenje | Karakteristike | Način ophođenja |
|------------------------------|--|---|
| Esencijalno | Posljedica složenosti poruke i stupnja interaktivnosti između elemenata poruke | Ne može se eliminirati, ali se može kontrolirati upotrebom jednostavnijih zadataka ili izostavljanjem određenog dijela interaktivnih elemenata kako bi se rasteretila radna memorija |
| Sadržajno irelevantno | Posljedica neadekvatnog instrukcijskog dizajna poruke | Može se eliminirati ako se prilikom instrukcijskog dizajna uzmu u obzir karakteristike ljudskog sustava za kognitivnu obradu informacija |
| Sadržajno relevantno | Posljedica angažmana primatelja poruke u dublje kognitivne procese za vrijeme obrade i formacije shema | Može se potaknuti angažiranjem primatelja poruke u odgovarajuće kognitivne procese pomoću instrukcijskog dizajna čija načela oblikovanja slijede način na koji funkcionira ljudski um |

2.2.5.1 Esencijalno kognitivno opterećenje

Esencijalno kognitivno opterećenje nastaje kao posljedica kognitivnih zahtjeva postavljenih na kapacitet radne memorije koji su odraz složenosti multimedijske poruke, odnosno količine elemenata koji se istovremeno trebaju obraditi u radnoj memoriji radi konstrukcije *shema* (Paas, F., Renkl, A. i Sweller, J., 2003; DeLeeuw, K. E. i Mayer, R. E., 2008). Broj elemenata koji se obrađuju ovisi o stupnju njihove interakcije. Element je ono što primatelj poruke treba usvojiti, a to je najčešće *shema* (Sweller, J., van Merriënboer, J. J. G. i Paas, F. G. W. C., 1998). Kod zadataka s elementima niskog stupnja interakcije, svaki se element može obraditi i usvojiti kao neovisna cjelina, čime se smanjuje opterećenje radne memorije, a samim time i esencijalno kognitivno opterećenje. Pri tome se elementi mogu obrađivati slijedno, umjesto simultano i nije potrebno zadržavati njihov veći broj u radnoj memoriji u trenutku obrade. Zadatci s elementima visokog stupnja interakcije sadrže složenije strukture što zahtjeva sposobnost istovremene manipulacije većeg broja elemenata u radnoj memoriji radi razumijevanja zadataka. Time se postavlja veliko opterećenje na kapacitet radne memorije (Sweller, J., van Merriënboer, J. J. G. i Paas, F. G. W. C., 1998).

Stupnjevi interakcije ne mogu se odrediti analizom instrukcijskog dizajna poruke, već prebrojavanjem interakcijskih elemenata s kojima se ljudi bave na određenoj razini znanja. Stoga, esencijalno kognitivno opterećenje odnosno stupanj interakcije, ovisi o složenosti poruke i znanju primatelja (Sweller, J., van Merriënboer, J. J. G. i Paas, F. G. W. C., 1998). Ono se ne može eliminirati utjecajem na instrukcijski dizajn, već smanjenjem složenosti poruke u početnoj fazi učenja upotrebom jednostavnijih zadataka ili izostavljanjem određenog dijela elemenata. Iako izostavljanje elemenata utječe na razinu kvalitete razumijevanja sadržaja, ono se ne može izbjeći kod poruka s visokim stupnjem interakcije. Izostavljeni elementi uključuju se u poruku naknadno, u kasnijoj fazi učenja, što omogućuje simultanu obradu svih esencijalnih dijelova poruke i u konačnici opterećuje radnu memoriju, ali je to jedini način da se postigne razumijevanje sadržaja. Iako se esencijalno opterećenje ne može eliminirati, moguće ga je kontrolirati oblikovanjem sadržaja za učenje upotrebom načela modaliteta, načela podjele (Mayer, R. E., 2009, prema Kassim, H., 2011) i načela pripreme obuke (Mayer, R. E. i Moreno, R., 2003; Mayer, R. E., 2009, prema Kassim, H., 2011; Mayer, R. E. i Alexander, P. A., 2011; Mayer, R. E., 2014c, prema Benassi, V. A., Overson, C. E. i Hakala, C. M., 2014).

2.2.5.2 Sadržajno irelevantno kognitivno opterećenje

Sadržajno irelevantno kognitivno opterećenje nastaje kao posljedica neadekvatnog instrukcijskog dizajna poruke gdje primatelj ulaže i troši svoje kapacitete na kognitivne procese koji nisu izravno povezani s procesom usvajanja znanja (DeLeeuw, K. E. i Mayer, R. E., 2008). Ovo se opterećenje može smanjiti intervencijom informacijskog i obrazovnog stručnjaka na instrukcijski dizajn tako da se prilikom oblikovanja poruke uzmu u obzir karakteristike ljudskog sustava za obradu informacija. To uključuje primjenu načela prostorne povezanosti i vremenske usklađenosti, načela koherentnosti, načela zalihosnosti i načela signalizacije (Mayer, R. E. i Moreno, R., 2003; Mayer, R. E., 2009, prema Kassim, H., 2011; Mayer, R. E. i Alexander, P. A., 2011; Mayer, R. E., 2014c, prema Benassi, V. A., Overson, C. E. i Hakala, C. M., 2014).

Sadržajno irelevantnom kognitivnom opterećenju automatski se pridodaje esencijalno kognitivno opterećenje što može nadići kapacitet radne memorije te spriječiti ili oštetiti proces usvajanja znanja. Intervencijom na instrukcijski dizajn može se postići najveći učinak kod poruka s vrlo visokim stupnjem interaktivnosti odnosno kod visokog esencijalnog opterećenja. Ako je esencijalno opterećenje nisko, kao rezultat niskog stupnja interakcije, tada visoko sadržajno irelevantno kognitivno opterećenje može biti manje štetno (Sweller, J., van Merriënboer, J. J. G. i Paas, F. G. W. C., 1998), jer totalno opterećenje u većini slučajeva ne prelazi kapacitet radne memorije. U tom slučaju i promjena dizajna poruke radi smanjenja opterećenja ima minimalan ili nikakav učinak (Paas, F., Renkl, A. i Sweller, J., 2003).

2.2.5.3 Sadržajno relevantno kognitivno opterećenje

Sadržajno relevantno kognitivno opterećenje nastaje kada se primatelj poruke angažira u dublje kognitivne procese koji su relevantni za proces usvajanja znanja, kao što su mentalno organiziranje sadržaja poruke i njegova povezivanja s predznanjem (DeLeeuw, K. E. i Mayer, R. E., 2008). Stupanj kognitivnog angažmana ovisi o dostupnom kapacitetu radne memorije, načinu prikaza sadržaja poruke kojim se pažnja primatelja usmjeruje na kognitivne procese relevantne za razumijevanje sadržaja (Sweller, J., van Merriënboer, J. J. G. i Paas, F. G. W. C., 1998), razini motivacije i predznanja (DeLeeuw, K. E. i Mayer, R. E., 2008; Mayer, R. E., 2014b). Povećanjem motivacije ili uloženog truda povećava se i kognitivni angažman. Ako je povećanje angažmana ujedno vezano i uz formaciju *shema* tada ono predstavlja povećanje

kognitivnog opterećenja. U konačnici, ovo opterećenje potiče proces razumijevanja sadržaja (Sweller, J., van Merrienboer, J. J. G. i Paas, F. G. W. C., 1998; Paas, F., Renkl, A. i Sweller, J., 2003), u slučaju kada je multimedijaska poruka oblikovana prema načelima koja slijede način na koji funkcionira ljudski um, što uključuje upotrebu načela personalizacije, načela razgovornog stila i načela virtualnog predavača (Mayer, R. E. i Moreno, R., 2003; Mayer, R. E., 2009, prema Kassim, H., 2011; Mayer, R. E. i Alexander, P. A., 2011; Mayer, R. E., 2014c, prema Benassi, V. A., Overson, C. E. i Hakala, C. M., 2014).

Prema *teoriji kognitivnog opterećenja*, esencijalno, sadržajno irelevantno i sadržajno relevantno kognitivno opterećenje doprinose konačnom kognitivnom opterećenju (Paas, F., Renkl, A. i Sweller, J., 2003), koje ne smije prijeći sveukupni kapacitet radne memorije. Kako bi primatelj poruke imao dovoljno kapaciteta za dublje kognitivne procese, potrebno je eliminirati irelevantno opterećenje i smanjiti esencijalno opterećenje (Sweller, J., van Merrienboer, J. J. G. i Paas, F. G. W. C., 1998; Mayer, R. E., 2009, prema Kassim, H., 2011; Mayer, R. E. i Alexander, P. A., 2011).

2.2.6 Obrada slika, govora i pisane riječi

Prema KTMUZ-u upotrebom multimedijске instruktivne poruke moguće je primatelja poruke angažirati u tri osnovna kognitivna procesa: obradu slike, obradu govora (naracije) i obradu pisane riječi. Navedeni procesi objašnjeni su pomoću sljedećih multimedijških prikaza:

- Prvi primatelj poruke (slika 4, gore) promatra multimedijški prikaz koji se sastoji od **statične slike i pisane riječi**. Statična slika obuhvaća grafički pokazivač u liku kornjače i geometrijski lik trokuta. Pisana riječ prikazuje programski kôd za iscertavanje trokuta.
- Drugi primatelj poruke (slika 4, dolje) promatra multimedijški prikaz koji se sastoji od **pokretne slike i govorene riječi ili naracije**. Pokretna slika prikazuje animirane pomake (promjene položaja ili translacije) grafičkog pokazivača u liku kornjače prilikom iscertavanja geometrijskog lika trokut. Govorena riječ ili naracija, u formi interaktivnog elementa, opisuje osnovne naredbe programskog kôda.

Programski kod
za iscrtavanje
TROKUTA

```
FD 40 RT 120
FD 40 RT 120
FD 40 RT 120
```

- ♦ Duljina stranice: 40
- ♦ Kut rotacije kornjače = $360/3 = 120$

Programski kod
za iscrtavanje
TROKUTA

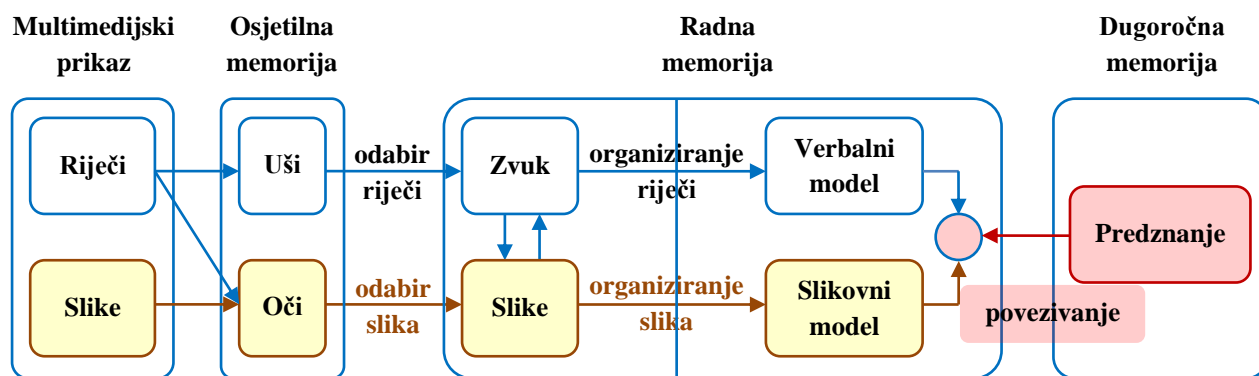
```
FD 40 RT 120
FD 40 RT 120
FD 40
```

Pokreni

- ♦ Duljina stranice: 40
- ♦ Kut rotacije kornjače = $360/3 = 120$

Slika 4. Primjer multimedijске poruke za obradu slike (grafički pokazivač u liku kornjače i geometrijski lik trokut), govora (opis osnovnih naredbi programskog kôda) i pisane riječi (prikaz programskog kôda)

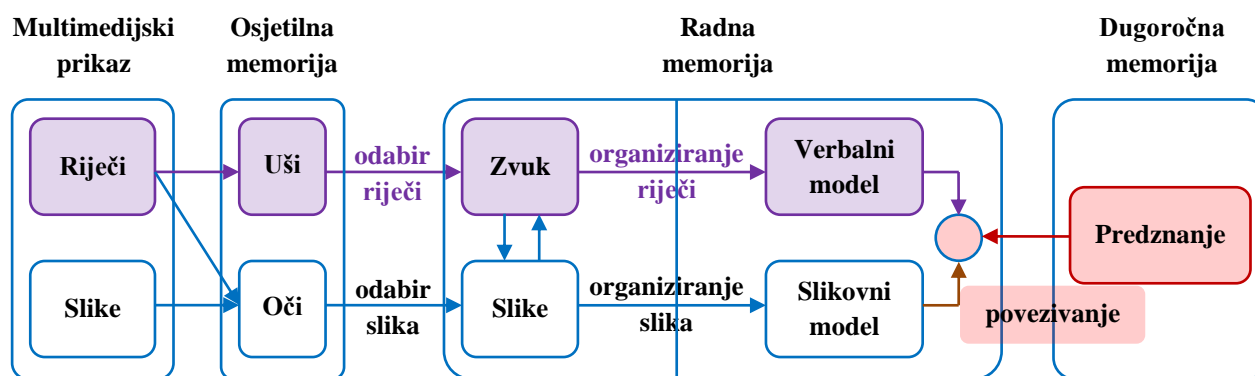
Slika 5 prikazuje kognitivni **proces obrade slike** kroz simbole žutih kvadratića i žutih strelica. Proces započinje opažanjem multimedijskog prikaza bilo statične (kornjača i trokut), bilo pokretne slike (animirani pomaci kornjače prilikom iscrtavanja trokuta), pomoću osjetilnog kanala vida (oči). Primatelj poruke kratko vrijeme zadržava slike kornjače i trokuta odnosno okvire animacije u vizualnoj osjetilnoj memoriji. Posvećivanjem pažnje slikama unosi se svjesnost u proces opažanja čime započinje aktivna obrada informacija i stvaranje dijelova vizualne predodžbe u radnoj memoriji. Nakon toga, primatelj organizira vizualni prikaz odabranih dijelova iz statičnih slika (kornjača i trokut), odnosno dijelove predodžbe koji predočuju uzročno-posljedične korake animacije (pomaci kornjače i iscrtavanje trokuta), u koherentnu strukturu ili slikovni mentalni model. Aktivna obrada završava povezivanjem novonastalog prikaza s predznanjem iz dugoročne memorije. Na primjer, oba primatelja poruke mogu upotrijebiti svoje predznanje iz geometrije kako bi razumjeli vezu između duljine stranice trokuta i veličine pomaka kornjače u ravnini. Međutim, drugi primatelj ima mogućnost povezati animirane pomake kornjače u koordinatnom sustavu sa znanjem kinematike (gibanje objekata ili tijela u prostoru), kao pomoć u razumijevanju konstruiranja geometrijskog lika trokuta. Ako je pri tome primatelj poruke stvorio i verbalni model postoji mogućnost da će ga pokušati povezati sa slikovnim modelom putem izgrađenih referentnih veza između dijelova vizualnih i zvučnih predodžbi iz percipiranih programskih naredbi (naracija) i pripadajućeg dijela slike (animirani pomaci kornjače).



Slika 5. Obrada slike prema KTMUZ. Izvor: Mayer, R. E. (2005, str. 43; 2014a, str. 52)

Slika 6 prikazuje kognitivni **proces obrade govora** kroz simbole ljubičastih kvadratića i ljubičastih strelica. Kada računalo putem zvučnika reproducira zvučni signal u formi govorene riječi ili naracije „Pomak kornjače za 40 piksela prema naprijed. Rotacija kornjače za 120 stupnjeva udesno“, primatelj poruke detektira zvukove uz pomoć osjetilnog kanala

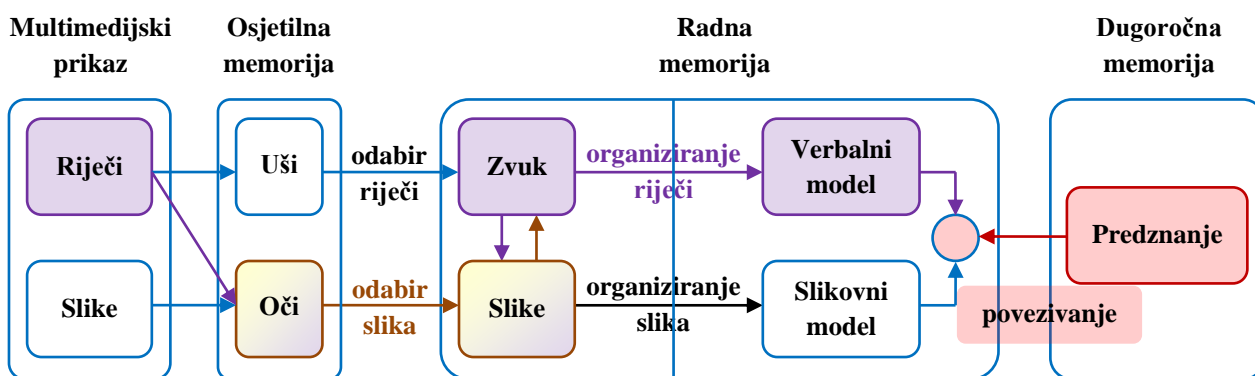
sluha (uši) i kratko vrijeme zadržava riječi u slušnoj osjetilnoj memoriji. Ako posveti pažnju tim riječima pokreće aktivnu obradu informacija odabiranjem njemu važnih zvukova i stvara dijelove zvučne predodžbe u radnoj memoriji. Kako zvučnu predodžbu čini skup riječi u formi neorganiziranih fragmenata, kao na primjer „*pomak 40, rotacija 120*“, u sljedećem koraku obrade dolazi do njihove organizacije u koherentnu strukturu ili verbalni mentalni model. U tom procesu, riječi iz zvučnog prikaza prelaze u formu s određenim značenjem. Na kraju, primatelj poruke može iskoristiti svoje predznanje i povezati riječi sa slikama, kao što je povezivanje riječi „*pomak 40, rotacija 120*“ sa statičnom ili pokretnom slikom kornjače i geometrijskog lika trokut duljine stranice 40 piksela te kuta rotacije od 120 stupnjeva.



Slika 6. Obrada govorene riječi prema KTMUZ. Izvor: Mayer, R. E. (2005, str. 43)

U opisanim obradama slika i govora kognitivni procesi odvijali su se u vizualnom/slikovnom kanalu i slušnom/verbalnom kanalu. Međutim, slika 7 prikazuje kako obrada informacija može biti međukanalna ako primatelj posjeduje dovoljno kognitivnog kapaciteta. Na primjer, drugi primatelj poruke može mentalno stvoriti zvukove prema odgovarajućoj vizualnoj predodžbi, kao što je mentalno izgovaranje riječi „*rotacija*“ u trenutku kada ugleda animaciju okretanja kornjače. Također, primatelj može mentalno stvoriti vizualnu predodžbu iz percipiranih riječi, kao što je vizualizacija pravca u trenutku kada čuje riječi „*pomak kornjače za 40 piksela*“. Na slici 7 prikazana je obrada pisane riječi koja predstavlja svojevrstni kognitivni izazov u obradi informacija. Kao primjer proučit će se prvi primatelj poruke koji promatra statične slike kornjače i geometrijskog lika trokut te čita pisane riječi pripadajućeg programskog kôda. Pisana riječ je prikazana vizualno i inicijalno se obrađuje putem osjetilnog kanala vida (oči). Kada primatelj poruke usmjeri svoju pažnju na neke od riječi programskog kôda one se prosljeđuju radnoj memoriji u formi jednog dijela vizualne predodžbe. Nadalje, mentalnim izgovaranjem dijela vizualne predodžbe riječi

prelaze u dijelove zvučne predodžbe i potom se obrađuju kao govor u slušnom/verbalnom kanalu. Na primjer, prikazane riječi „FD 40 RT 120“ ulaze preko osjetila vida u vizualnu memoriju te se prosljeđuju radnoj memoriji kao dio vizualne predodžbe. Kada primatelj poruke mentalno izgovori te riječi one postaju zvuk i prenose se u verbalni kanal te obrađuju kao govor. Kognitivni izazov se javlja jer pisana riječ prolazi put od vizualnog do verbalnog kanala i pri tome se natječe za kognitivni prostor u radnoj memoriji sa vizualnom predodžbom opaženih slika koje se istovremeno obrađuju u vizualnom kanalu. Zato KTMUZ sugerira istovremenu upotrebu govorene riječi i slike, umjesto kombinacije pisane riječi i slike, kako bi se djelomično oslobodio vizualni kanal.



Slika 7. Obrada pisane riječi prema KTMUZ. Izvor: Mayer, R. E. (2005, str. 43)

2.2.7 Načela kognitivne teorije multimedijskog usvajanja znanja

Kognitivna teorija multimedijskog usvajanja znanja (KTMUZ) do sada je u svojem kontinuiranom razvoju razvila sveukupno 13 osnovnih i 11 naprednih načela u svrhu oblikovanja učinkovite *multimedijske instruktivne poruke* za unapređenje zapamćivanja i razumijevanja sadržaja (Mayer, R. E., 2001, 2005, 2009, 2014a). U narednim poglavljima objašnjena su načela primijenjena za razvoj i oblikovanje *multimedijske instruktivne poruke za programski jezik Logo* (MIPL) koja čini temeljni materijal korišten u ovom doktorskom istraživanju (vidi poglavlje 3):

- (1) Osam osnovnih načela: *načelo multimedija*, *načelo prostorne povezanosti*, *načelo vremenske usklađenosti*, *načelo koherentnosti*, *načelo modaliteta*, *načelo zalihosnosti*, *načelo signalizacije*, *načelo individualnih razlika*;

- (2) Napredno *načelo animacije i interaktivnosti*;
- (3) *Načelo raščlanjivanja* modela kognitivnog procesa multimodalnog razumijevanja (vidi poglavlje 2.3).

2.2.7.1 Načelo multimedija

Načelo multimedija pretpostavlja da primatelji poruke bolje usvajaju sadržaj prezentiran riječima i slikom nego sadržaj prezentiran samo riječima (Mayer, R. E., 2001, 2005; Mayer, R. E., 2009, prema Mayer, R. E. i Alexander, P. A., 2011).

Multimedijska instrukcija javlja se kada instruktivna poruka sadrži riječi i slike (Mayer, R. E., 2009, prema Mayer, R. E. i Alexander, P. A., 2011). *Multimedijska instruktivna poruka* je poruka koja sadrži riječi i slike s ciljem unaprjeđenja zapamćivanja i razumijevanja sadržaja (Mayer, R. E., 2009, prema Mayer, R. E. i Alexander, P. A., 2011). Pojam *riječi* obuhvaća govoreni (naracija, sintetizirani govor) i/ili pisani tekst (na papiru ili računalnom zaslonu). Pojam *slike* obuhvaća statičnu sliku (ilustracija, crtež, fotografija, mapa, grafikon, dijagram, tablice) i/ili pokretnu sliku (animacija, video zapisi, simulacija) (Mayer, R. E., 2009, prema Mayer, R. E. i Alexander, P. A., 2011). Pod terminom *bolje usvajanje sadržaja* podrazumijeva se unaprjeđenje zapamćivanja i razumijevanja sadržaja u procesu usvajanja znanja iz multimedijskih instruktivnih prikaza.

Slika je holistička nelinearna prezentacija informacija, puno bliža vizualnom osjetilnom iskustvu čovjeka nego tekst. Prikladna je za prikaz prostornih i konkretnih informacija čije opažanje zahtijeva određene sposobnosti ljudskog vizualnog sustava za percepciju prostornih konfiguracija (Schnotz, W., 1993, prema Roy, M. C., 2000). Tekst se sastoji od diskretnih jedinica prikazanih u linearnom nizu. Prikladan je za tumačenje apstraktnog i općenitog sadržaja što zahtijeva određeni mentalni napor. Ako se riječi i slike promatraju kao informacijski ekvivalentni objekti koji se iz predmetnog okruženja pohranjuju u ljudski um, multimedijski prikaz postaje nepotreban za prijenos i obradu informacija. Kada primatelj poruke pohrani i usvoji informaciju putem jednog načina prikaza (npr. riječi), tada dodatni prijenos iste informacije u drugom formatu (npr. slika) postaje redundantan. Međutim, prema *teoriji dvostrukog kodiranja* (Paivio, A., 1986, prema Mayer, R. E., 2005) ljudi posjeduju dva kvalitativno različita kanala za obradu slikovnih i verbalnih informacija: vizualni i slušni kanal. Opažanjem multimedijskih prikaza čovjek u radnoj memoriji stvara vizualne i zvučne mentalne predodžbe koje po svojoj prirodi nisu informacijski ekvivalentne. Stvorene predodžbe međusobno se nadopunjuju, ali ne zamjenjuju jedno drugo (Mayer, R. E., 2001).

Prema tome, riječi i slike čine dva kvalitativno različita sustava za prikaz znanja. Takav sustav omogućuje učinkoviti prijenos znanja u slučaju kada je jedan od kanala za obradu informacija blokiran, jer primatelj poruke više preferira jedan format ili ima veću sposobnost upotrebe jednog formata u odnosu na drugi.

Prva upotreba instrukcijske vizualizacije u svrhu učinkovitijeg razumijevanja tekstualnih sadržaja vuče svoje korijenje iz 17. stoljeća. Danas, ona živi kroz knjige, film i računalno okruženje (Mayer, R. E. i Alexander, P. A., 2011). Prema Mayeru (2011) instrukcijska vizualizacija/slika/grafika jest vizualno-prostorna reprezentacija čija je osnovna namjera unaprijediti proces usvajanja znanja, pri čemu može poprimiti različite karakteristike (Mayer, R. E. i Alexander, P. A., 2011, str. 428):

- *Realizam* – slike mogu biti visoko realistične (npr. fotografija ili video zapis) ili nisko realistične (npr. iscrtana linija ili animacija iscrtavanja linije).
- *Dinamičnost* – slike mogu biti statične (npr. crtež ili fotografija) ili pokretne (npr. animacija ili video zapis).
- *Interaktivnost* – slike mogu biti interaktivne (npr. niz crteža ili animacija čija se brzina izmjene okvira može kontrolirati od strane korisnika) ili neinteraktivne (npr. crtež ili kontinuirana animacija).
- *Dimenzionalnost* – slike mogu biti prikazane u 2D ili 3D formi.
- *Vizualno-prostorni karakter* – slike mogu biti vizualne reprezentacije (npr. crtež ili fotografija objekta) ili prostorne reprezentacije (grafikon ili tablica ili mapa).
- *Prijenosno sredstvo ili medij* – slike se mogu prikazati otisnute na papiru ili na računalnom zaslonu.

Mnogi su istraživači klasificirali ilustracije prema funkcijama koje one obnašaju u odnosu na tekst (Duchastel, P. i Waller, R., 1979, prema Anglin, G. J., Vaez, H. i Cunningham, K. L., 2004; Levin, J. R., 1981, prema Anglin, G. J., Vaez, H. i Cunningham, K. L., 2004; Levie, W. H. i Lentz, R., 1982, prema Anglin, G. J., Vaez, H. i Cunningham, K. L., 2004; Mayer, R. E., 1993, prema Roy, M. C., 2000). Levin (1981, prema Roy, M. C., 2000, str. 12) navodi pet funkcija ilustracija:

- (1) **Dekorativna (engl. *decorational*)** – slika se koristi za uređivanje stranice čineći je što atraktivnijom kako bi se povećala motivacija čitatelja. Ova funkcija slike nije povezana sa sadržajem teksta i nema učinka na razumijevanje sadržaja.

- (2) **Opisna (engl. *representational*)** – slika opisuje odjeljak teksta ili cijeli tekst „pričavanjem“ sadržaja u slikovnoj formi. Ovo je najčešća i najraširenija vrsta tekstualnih ilustracija.
- (3) **Organizacijska (engl. *organizational*)** – slika povezuje sadržaj teksta u organizacijsku strukturu (na primjer, ilustracija koja prikazuje korake pružanja prve pomoći).
- (4) **Objašnjavajuća (engl. *interpretational*)** – slika razjašnjava teško razumljive tekstualne sadržaje (na primjer, vizualni opis očnog tlaka) ili oslikava složene i nepoznate koncepte.
- (5) **Transformacijska (engl. *transformational*)** – slika pomaže čitatelju u dekodiranju, povezivanju i dohvatanju tekstualnog sadržaja iz dugoročne memorije. Uključuje mnemoničke komponente za unapređenje čitateljevih sposobnosti zapamćivanja tekstualnih informacija. Ova funkcija slike izravno utječe na memoriju čitatelja.

Mayer (1993, prema Roy, M. C., 2000, str. 13) je modificirao navedenu Levinovu klasifikaciju predloživši podjelu ilustracija prema njihovu utjecaju na kognitivne funkcije čovjeka:

- **Dekorativne ilustracije (engl. *decorational*)** zauzimaju prostor na stranici bez isticanja poruke odjeljka i ne utječu na kognitivne sposobnosti.
- **Opisne ilustracije (engl. *representational*)** opisuju jedan element teksta i utječu na sposobnost odabira relevantnih tekstualnih informacija.
- **Organizacijske ilustracije (engl. *organizational*)** opisuju elemente određenog objekta i odnose između elemenata. Utječu na sposobnost odabira i organiziranja tekstualnih informacija.
- **Objašnjavajuće ilustracije (engl. *explanative*)** objašnjavaju rad nekog sustava. Utječu na sposobnost odabira, organiziranja i povezivanja tekstualnih informacija s postojećim znanjem pohranjenim u dugoročnoj memoriji.

U većini je svojih istraživanja Mayer primjenjivao nisko realistične, neinteraktivne, 2D vizualne reprezentacije, prikazane tiskanim putem ili preko računalnog zaslona (Mayer, R. E. i Alexander, P. A., 2011). Pri tome se primarno fokusirao na upotrebu objašnjavajućih ilustracija – niz okvira koji prikazuju topologiju sustava (engl. *system topology*), s natpisima za glavne komponente unutar strukture sustava i ponašanje tih komponenti (engl. *component*

behavior) u kombinaciji s popisom glavnih promjena koje komponente prolaze u radu sustava (npr. način rada automobilske kočnice). Takve ilustracije predstavljaju svojevrsan konceptualni model pomoću kojega primatelji poruke mogu dobiti uvid u način rada nekog sustava te razviti vještine u predviđanju kauzalnog ponašanja sustava, čime se potiče izgradnja pokretljivih i održivih metalnih modela (Bayman, P. i Mayer, R. E., 1988; Mayer, R. E. i Gallini, J. K., 1990). Objašnjavajuće ilustracije, kao vizualni dodatak odgovarajućem odjeljku teksta s opisom pojedinačnog okvira, pokazale su se najpogodnijima za pojednostavljenje složenih znanstvenih objašnjenja (uzročno-posljedični opis procesa), te najučinkovitije u unaprjeđenju zapamćivanja sadržaja i *transfera* znanja (Mayer, R. E., 1989b; Mayer, R. E. i Gallini, J. K., 1990; Mayer, R. E. i sur., 1996). Međutim, Mayer i sur. (1996) su nizom od 3 eksperimenta pokazali kako niz označenih ilustracija, umjesto da služe kao odjeljak tekstu, može stajati samostalno kao *multimedijski sažetak* sa sljedećim karakteristikama:

- **Koncizan** – vizualno objašnjenje je prikazano upotrebom malog broja jednostavnih ilustracija koje oslikavaju glavne korake procesa, a verbalno objašnjenje je prikazano upotrebom malog broja riječi ili sažetih rečenica koje opisuju glavne korake procesa. Vizualna i verbalna objašnjenja odnose se samo na dijelove i procese esencijalne za razumijevanje rada sustava. Ova karakteristika omogućava aktivaciju prvog (*odabir relevantnih riječi iz prikazanog teksta ili naracije*) i drugog (*odabir relevantnih slika iz prikazanih ilustracija*) kognitivnog procesa KTMUZ-a.
- **Koherentan** – vizualna i verbalna objašnjenja prikazana su u nizu uzročno-posljedičnih veza, gdje su promjene stanja u jednom dijelu sustava jasno povezana s promjenama stanja u drugom dijelu sustava. Ova karakteristika omogućava aktivaciju trećeg (*organiziranje odabranih riječi ili dijelova zvučne predodžbe u verbalni mentalni model*) i četvrtog (*organiziranje odabranih slika ili dijelova vizualne predodžbe u slikovni mentalni model*) kognitivnog procesa KTMUZ-a
- **Koordiniran** – svaki korak u procesu objašnjavanja prikazan je i vizualno i verbalno tako što svaka vizualna ilustracija sadrži odgovarajuće verbalno objašnjenje. Ova karakteristika omogućava aktivaciju petog kognitivnog procesa KTMUZ-a, odnosno izgradnju referentnih mentalnih veza između konstruiranog verbalnog i slikovnog modela i njihovih međusobnih relacija u jedan zajednički integrirani mentalni model.

Načelo multimedije utvrđeno je u 11 eksperimentalnih istraživanja (Mayer, R. E., 2014c, prema Benassi, V. A., Overson, C. E. i Hakala, C. M., 2014), u kojima su ispitanici postigli bolje rezultate na *transferu* znanja u procesu učenja različitih znanstvenih sadržaja (mehaničke pumpe, kočnice i generatori, prirodni fenomeni), prikazanih riječima i slikama naspram sadržaja prikazanih samo riječima (naracija i animacija ili samo naracija; tekst i ilustracije ili samo tekst). Kako bi se utvrdilo načelo multimedije u autentičnim okruženjima za učenje, provedena su tri istraživanja u kojima su ispitanici poučavani o načelima učenja putem usmenog izlaganja, nakon čega im je prezentiran primjer ili putem video zapisa ili u tiskanom obliku. Studenti kojima je prezentiran video zapis postigli su bolje rezultate u *transferu* znanja (Moreno, R. i Valdez, A., 2007; Moreno, R. i Ortegado-Layne, L., 2008, prema Mayer, R. E. i Alexander, P. A., 2011).

U konačnici, iako usvajanje znanja iz simultanog prikaza riječi i slika može rezultirati u dubljem razumijevanju sadržaja, nisu svi slikovni prikazi jednako učinkoviti (Mayer, R. E. i Alexander, P. A., 2011). Načelo multimedije treba biti podržano preostalim načelima KTMUZ-a kako bi se smanjilo sadržajno irelevantno kognitivno opterećenje, kontroliralo esencijalno kognitivno opterećenje i potaknulo sadržajno relevantno kognitivno opterećenje (Mayer, R. E., 2014c).

2.2.7.2 Načelo prostorne povezanosti

Načelo prostorne povezanosti pretpostavlja da primatelji poruke bolje usvajaju sadržaj kod kojeg su riječi i slike prostorno integrirani nego prostorno razdvojeni (Mayer, R. E., 2001, 2005; Mayer, R. E., 2009, prema Mayer, R. E. i Alexander, P. A., 2011).

Načelo se temelji na osnovnim pretpostavkama KTUMZ-a: (1) ljudski kognitivni sustav obuhvaća odvojene kanale za obradu vizualnih i verbalnih informacija; (2) svaki kanal ima ograničeni kapacitet spoznaje; (3) smisleno usvajanje znanja ovisi o nizu kognitivnih procesa, kao što su odabir – organizacija – integracija multimedijских sastavnica. Kod multimedijskog prikaza u tiskanom obliku ili na računalnom zaslonu, gdje su riječi i slike prostorno razdvojeni, postoji mala vjerojatnost da će primatelji poruke uspjeti zadržati oba prikaza istovremeno u radnoj memoriji, jer su kognitivni kapaciteti većinom iskorišteni za vizualno pretraživanje informacija, umjesto za spoznajne procese (Mayer, R. E., 2001). Ako su riječi i slike prostorno integrirani, primatelji poruke ne trebaju vizualno pretraživati riječi i njima pripadajuće slike. Time se povećava mogućnost simultanog zadržavanja odgovarajućeg

verbalnog i vizualnog prikaza u radnoj memoriji i smanjuje sadržajno irelevantno kognitivno opterećenje, jer se kognitivni kapaciteti primarno posvećuju procesima koji su relevantni za izgradnju referentnih mentalnih veza između odgovarajućih riječi i slika i konstrukciju mentalnog modela (Mayer, R. E. i Alexander, P. A., 2011; Mayer, R. E., 2014c, prema Benassi, V. A., Overson, C. E. i Hakala, C. M., 2014).

Ovo se načelo u literaturi može pronaći i pod nazivom *efekt podijeljene pažnje* (engl. *split-attention effect*) (Chandler, P. i Sweller, J., 1992; Sweller, J., van Merriënboer, J. J. G. i Paas, F. G. W. C., 1998), koji se javlja kada primatelji poruke podijele svoju pažnju između različitih izvora informacija (grafički, tekstualni) koje moraju mentalno integrirati unutar prikazanog nastavnog sadržaja. U tom se slučaju postavljaju veći kognitivni zahtjevi na radnu memoriju što može narušiti proces usvajanja znanja.

Načelo prostorne povezanosti utvrđeno je u svih 22 eksperimentalna istraživanja (Mayer, R. E., 2014c, prema Benassi, V. A., Overson, C. E. i Hakala, C. M., 2014), u kojima su ispitanici postigli bolje rezultate na *transferu* znanja u procesu učenja različitih znanstvenih sadržaja prikazanih u tiskanom ili računalnom obliku: rad automobilskih kočnica (Mayer, R. E., 1989b; Johnson, C. I. i Mayer, R. E., 2012), formiranje munje (Mayer, R. E. i sur., 1995 prema Mayer, R. E., 2005; Moreno, R. i Mayer, R. E., 1999), rad ljudskog srca i respiratornog sustava (Chandler, P. i Sweller, J., 1991), električni inženjering (Chandler, P. i Sweller, J., 1991, 1992; Tindall-ford, S. K., Chandler, P. i Sweller, J., 1997, prema Stiller, K. D., 2007), statistika (Bodemer, D. i sur., 2004) i dr.

2.2.7.3 Načelo vremenske usklađenosti

Načelo vremenske usklađenosti pretpostavlja da primatelji poruke bolje usvajaju sadržaj sa simultanim prikazom riječi i slika nego sadržaj sa slijednom prikazom (Mayer, R. E., 2001, 2005; Mayer, R. E., 2009, prema Mayer, R. E. i Alexander, P. A., 2011).

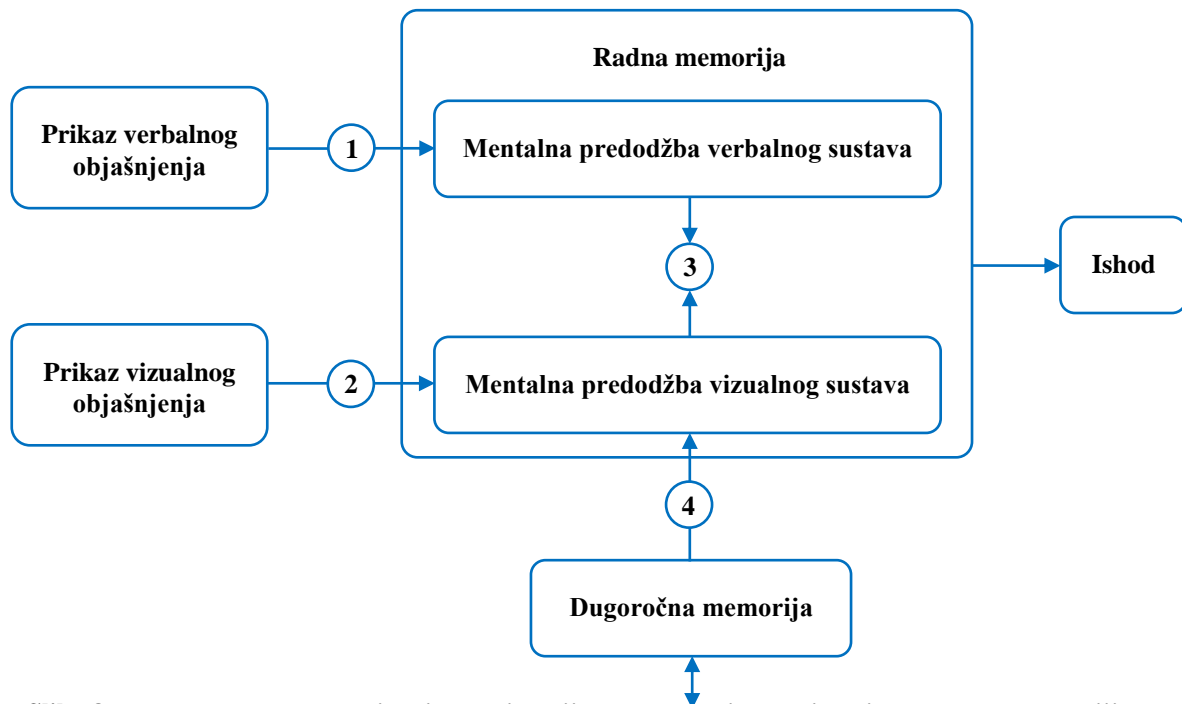
Ljudski kognitivni sustav podržava simultanu obradu informacija, jer sadrži odvojene verbalne i vizualne kanale. Dok se govoreni tekst ili naracija može obrađivati u jednom kanalu, paralelna obrada odgovarajućeg segmenta pokretne slike ili animacije može se odvijati u vizualnom kanalu. Zadržavanje odgovarajućeg verbalnog i vizualnog prikaza istog događaja u radnoj memoriji u isto vrijeme povećava mogućnost izgradnje referentnih mentalnih veza između tih prikaza, što je ključan spoznajni proces za smisleno usvajanje znanja. Nasuprot tome, upotreba slijednog multimedijskog prikaza ne uzima u obzir karakteristike ljudskog kognitivnog sustava. Ako su riječi i slike vremenski razdvojene,

primatelji poruke moraju prvo obraditi cijelu naraciju prije nego što se posvete animaciji (i obrnuto). Zbog strogih ograničenja radne memorije, samo se mali segment naracije zadržava u verbalnoj radnoj memoriji u trenutku pokretanja animacije (ili se samo mali segment animacije zadržava u vizualnoj radnoj memoriji u trenutku započinjanja naracije). Takva obrada otežava i sprečava izgradnju referentnih mentalnih veza između riječi i slika, a time i razumijevanje sadržaja (Mayer, R. E., 2001).

Kod simultanog prikaza naracije i animacije primatelja poruke se potiče na izgradnju triju vrsta mentalnih veza (slika 8), (Mayer, R. E. i Anderson, R. B., 1991; Mayer, R. E. i Sims, V. K., 1994):

- (1) *predstavničkih mentalnih veza* (engl. *representational connections*) između percipiranih riječi (naracija) i dijelova mentalne zvučne predodžbe u radnoj memoriji;
- (2) *predstavničkih mentalnih veza* između opaženih slika (okviri animacije) i dijelova mentalne vizualne predodžbe u radnoj memoriji;
- (3) *referentnih mentalnih veza* (engl. *referential connections*) između dijelova zvučnih i vizualnih predodžbi (verbalnog i slikovnog mentalnog modela) u radnoj memoriji. Izgradnja referentnih mentalnih veza, odnosno međusobno povezivanje verbalnog i slikovnog mentalnog modela esencijalno je za postizanje smislenog usvajanja znanja iz multimedijskog prikaza i njegova pohranjivanja u dugoročnu memoriju.

Načelo vremenske usklađenosti utvrđeno je u svih 9 eksperimentalnih istraživanja (Mayer, R. E., 2014c, prema Benassi, V. A., Overson, C. E. i Hakala, C. M., 2014), u kojima su ispitanici postigli bolje rezultate na *transferu* znanja u procesu učenja različitih znanstvenih sadržaja prikazanih u računalnom obliku: rad automobilskih kočnica (Mayer, R. E. i Anderson, R. B., 1992; Mayer, R. E. i Moreno, R., 1998; Mayer, R. E. i sur., 1999), formiranje munje (Mayer, R. E. i Moreno, R., 1998; Mayer, R. E. i sur., 1999), rad respiratornog sustava (Mayer, R. E. i Sims, V. K., 1994), rad biciklističke pumpe (Mayer, R. E. i Anderson, R. B., 1991, 1992; Mayer, R. E. i Sims, V. K., 1994) i dr.



Slika 8. Model dvostrukog kodiranja multimedijuskog usvajanja znanja prilagođen prema teoriji dvostrukog kodiranja (Paivio, A, 1986, prema Mayer, R. E., 2005; Clark, J. M. i Paivio, A., 1991). Broj 1 odnosi se na izgradnju predstavničkih verbalnih veza; broj 2 odnosi se na izgradnju predstavničkih vizualnih veza; broj 3 odnosi se na izgradnju referentnih veza; broj 4 odnosi se na dohvaćanje informacija iz dugoročne memorije. Izvor: Mayer, R. E. i Sims, V. K. (1994), str. 390.

Načelo vremenske usklađenosti i načelo prostorne povezanosti dva su važna faktora u oblikovanju multimedijske poruke kojom se potiču zapamćivanje i razumijevanje sadržaja. Oba načela se temelje na istim pretpostavkama: primatelji poruke imaju veću mogućnost izgraditi referentne mentalne veze između vizualnih (statična slika, animacija) i verbalnih (pisana riječ, naracija) prikaza kada ih mogu obrađivati u radnoj memoriji u isto vrijeme. Međutim, iako su načela slična, postoje i važne razlike. Primjena načela prostorne povezanosti važna je za oblikovanje izgleda stranice u udžbeniku ili okvira na računalnom zaslonu. Pri tome se sadržaj inicijalno obrađuje putem kanala vida (tiskani tekst, ilustracije, animacije). Nasuprot tome, načelo vremenske usklađenosti uzima u obzir vremenski faktor u računalnom okruženju i odnosi se na povezivanje riječi u formi govorenog teksta i pokretnih slika kod multimedijških prikaza. Stoga, ono je isključivo fokusirano na sadržaje koji se obrađuju putem kanala vida (animacija) i sluha (naracija), pri čemu je vremenska obrada sadržaja kontrolirana od strane instrukcijskog dizajnera koji odlučuje hoće li prvo prikazati samo riječi i potom samo grafiku, ili obrnuto (Mayer, R. E., 2001).

2.2.7.4 Načelo koherentnosti

Načelo koherentnosti pretpostavlja da primatelji poruke bolje usvajaju sadržaj kada su sadržajno nerelevantni elementi izostavljeni iz multimedijske poruke (Mayer, R. E., 2001, 2005; Mayer, R. E., 2009, prema Mayer, R. E. i Alexander, P. A., 2011). Multimedijska instruktivna poruka je potencijalno *koherentna* ako strukturalni odnosi između njenih elemenata nisu proizvoljni, već su usmjereni u formiranje kognitivnog niza uzročno-posljedičnih veza kojima se opisuje određeni događaj. Načelo se može rastaviti na tri komplementarne verzije (Mayer, R. E., 2001):

- (1) Proces usvajanja znanja se narušava dodavanjem zanimljivih, ali nerelevantnih riječi i slika u multimedijski prikaz.
- (2) Proces usvajanja znanja se narušava dodavanjem zanimljivih, ali nerelevantnih zvukova i glazbe u multimedijski prikaz.
- (3) Proces usvajanja znanja se unaprjeđuje odbacivanjem nebitnih riječi iz multimedijskog prikaza. Ovo se postiže upotrebom konciznog, koherentnog i koordiniranog multimedijskog sažetka (vidi poglavlje 2.2.7.1).

Multimedijski prikaz koji sadrži riječi i slike, oblikovan prema načelima oblikovanja, moguće je poboljšati i učiniti interesantnijim dodavanjem zanimljivog sadržaja, kao što su tekst (npr. umetanje dodatnih rečenica u postojeći odjeljak teksta) i slike (npr. postavljanje slika uz odgovarajući odjeljak teksta). U tom je slučaju, zanimljiv sadržaj isključivo relevantan za temu poučavanja, ali nema konceptualnu važnost (ne odnosi se na uzročno-posljedični proces objašnjavanja prikazanog događaja), što je ključan čimbenik za proces razumijevanja sadržaja. Prema Harpu i Mayeru (1997, 1998) takva se vrsta sadržaja naziva *zavodljivi detalji* (engl. *seductive details*), pri čemu se zanimljiv, ali nerelevantan tekst dodan odjeljku teksta naziva *zavodljivi tekst* (engl. *seductive text*), a zanimljive, ali nerelevantne ilustracije dodane odjeljku teksta *zavodljive ilustracije* (engl. *seductive illustrations*). *Zavodljivi detalji*, u bilo kojoj formi, predstavljaju irelevantno sadržajno opterećenje koje može preopteretiti radnu memoriju te otežati proces razumijevanja sadržaja i konstrukcije znanja (Mayer, R. E., 2009, prema Kassim, H., 2011). Opravdanje za upotrebu zavodljivih detalja počiva u *teoriji emocionalnog interesa*, prema kojoj primatelji poruke bolje usvajaju znanje kada su emocionalno potaknuti sadržajem poruke. Međutim, istraživanja su utvrdila kako takva vrsta emocionalnog uzbuđenja u kojoj emocije utječu na spoznaju ne pridonosi boljem razumijevanju tekstualnih sadržaja (Harp, S. E. i Mayer, R. E., 1997, 1998). Nasuprot

teorije emocionalnog interesa nalazi se *teorija kognitivnog interesa* (Kintsch, 1990, prema Mayer, R. E., 2001), prema kojoj spoznaja utječe na emocije i primatelji poruke uživaju u sadržaju koji mogu razumjeti. Kognitivni interes proizlazi iz primateljevog zadovoljstva zbog sposobnosti razumijevanja prikazanog sadržaja. Prema KTMUZ, dodavanje zavodljivih detalja multimedijskoj poruci može imati nekoliko negativnih učinaka (Harp, S. E. i Mayer, R. E., 1998):

- (1) dodavanjem zavodljivih detalja moguće je odvući pažnju primatelja poruke od sadržajno relevantnih informacija za vrijeme odabira relevantnih riječi ili slika iz prikazanog teksta ili ilustracija (engl. *distraction hypothesis*). U ovom slučaju minimiziranje učinaka zavodljivih detalja može se postići primjenom načela signalizacije (vidi poglavlje 2.2.7.8), odnosno usmjeravanjem pažnje na strukturalno relevantne informacije u sadržaju poruke.
- (2) umetanjem zavodljivih detalja u prikazano objašnjenje nekog događaja može poremetiti sposobnost izgradnje kognitivnog niza uzročno-posljedičnih veza između glavnih koraka u tom događaju (engl. *disruption hypothesis*), odnosno poremetiti procese organizacije informacija u koherentnu strukturu ili mentalni model u radnoj memoriji. I u ovom slučaju minimiziranje učinaka zavodljivih detalja može se postići primjenom načela signalizacije nad odjeljkom teksta koji sadrži zavodljive detalje kako, bi primatelj poruke prepoznao odnose i formirao uzročno-posljedične veze u prikazanom događaju.
- (3) dodavanjem zavodljivih detalja primatelji poruke mogu stvoriti koherentne mentalne predodžbe na temelju strukturalno nerelevantnih informacija, aktivirati neprikladno predznanje iz dugoročne memorije i suštinski narušiti proces usvajanja znanja (engl. *diversion hypothesis*). U ovom slučaju minimiziranje učinaka zavodljivih detalja može se postići smještanjem odjeljka teksta sa zavodljivim detaljima na kraj poruke, kako bi primatelj do tog trenutka već konstruirao mentalni model događaja na temelju sadržajno relevantnih informacija.

Uz zavodljive riječi i slike, u multimedijску poruku moguće je dodati i razne zvukove ili pozadinsku glazbu kako bi se poruka učinila zabavnijom. Prema KTMUZ, primatelji poruke posjeduju odvojene kanale za obradu vizualnih i verbalnih informacija, pri čemu je svaki kanal ograničenog kapaciteta. U slučaju kada multimedijška poruka sadrži naraciju i animaciju, naracija se obrađuje u slušnom kanalu, a animacija u vizualnom kanalu. Ako se u takvu poruku dodaju zvukovi ili pozadinska glazba njihova obrada u slušnom kanalu

konkurira obradi naracije zbog ograničenog kapaciteta kanala. Ovisno o tome koliko je kognitivnog kapaciteta iskorišteno za obradu zvuka i glazbe, primatelju će ostati na raspolaganju preostali dio kapaciteta za posvećivanje pažnje naraciji, organiziranje percipiranih riječi (govor) u verbalnu strukturu i povezivanje sa vizualnom informacijom. Na temelju KTMUZ-a u ovom će slučaju doći do efekta koherentnosti, gdje dodavanje zanimljivog sadržaja u multimedijску poruku u formi zvuka i glazbe narušava proces usvajanja znanja (Mayer, R. E., 2001).

Načelo koherentnosti utvrđeno je u 22 od 23 eksperimentalna istraživanja (Mayer, R. E., 2014c, prema Benassi, V. A., Overson, C. E. i Hakala, C. M., 2014), u kojima su ispitanici postigli bolje rezultate na *transferu* znanja u procesu učenja različitih znanstvenih sadržaja prikazanih u tiskanom ili računalnom obliku: formiranje munje (Mayer, R. E. i sur., 1996; Harp, S. E. i Mayer, R. E., 1997, 1998; Moreno, R. i Mayer, R. E., 2000), rad kočnica (Moreno, R. i Mayer, R. E., 2000), virusi u ljudskom tijelu i proces deglutacije (Mayer, R. E. i sur., 2008) i dr. Prema graničnim uvjetima za primjenu načela koherentnosti pokazalo se da načelo ima najveći učinak kod ispitanika s nižom razinom kapaciteta radne memorije, kod usvajanja sadržaja čiju brzinu prikaza određuje dizajner sustava te kada su dodatni detalji vrlo zanimljivi (Rey, G. D., 2012, prema Benassi, V. A., Overson, C. E. i Hakala, C. M., 2014; Mayer, R. E., Fiorella, L., 2014, prema Benassi, V. A., Overson, C. E. i Hakala, C. M., 2014)

2.2.7.5 Načelo modaliteta

Načelo modaliteta pretpostavlja da primatelji poruke bolje usvajaju sadržaj prezentiran animacijom i govorenim tekstom (naracija), nego sadržaj prezentiran animacijom i pisanim tekstom (tekst na računalnom zaslonu) (Mayer, R. E., 2001, 2005; Mayer, R. E., 2009, prema Mayer, R. E. i Alexander, P. A., 2011). Učinak modaliteta sastoji se od dva procesa (Stiller, K. D., 2007): preopterećenja vizualno/slikovnog kanala i efekta podijeljene pažnje (engl. *split-attention effect*).

Prema KTMUZ ljudi posjeduju odvojene kanale za obradu vizualno/slikovnih i slušno/verbalnih informacija. Kad se riječi prikažu kao pisani tekst na računalnom zaslonu, vizualni kanal istovremeno preuzima obradu riječi (barem u početku, a poslije se obrada nastavlja u verbalnom kanalu) i slika (animacija). U isto to vrijeme, verbalni kanal ostaje neiskorišten. Kako svaki kanal ima ograničeni kapacitet za obradu informacija, postoji velika vjerojatnost da će doći do kognitivnog preopterećenja vizualnog kanala što će narušiti aktivnu

obradu informacija, odnosno kognitivne procese odgovorne za razumijevanje sadržaja poruke, a samim time i konstrukciju znanja (Mayer, R. E., 2001). Nasuprot tome, kad se riječi prikažu u formi naracije one direktno ulaze u verbalni kanal na obradu i time oslobađaju vizualni kanal od nepotrebnog opterećenja. Na taj se način kognitivno opterećenje balansira između dva kanala i sačuvani spoznajni resursi radne memorije mogu se premjestiti na sadržajno relevantno kognitivno opterećenje.

Efekt podijeljene pažnje (engl. *split-attention effect*) javlja se kada primatelj poruke podijeli svoju pažnju između različitih izvora informacija (riječi, slike) koje je potrebno mentalno integrirati kako bi se postiglo razumijevanje sadržaja (Chandler, P. i Sweller, J., 1992; Sweller, J., van Merriënboer, J. J. G. i Paas, F. G. W. C., 1998). Ako su pri tome izvori informacija vremenski i prostorno neusklađeni i nepovezani, primatelj mora uložiti puno kognitivnog napora kako bi povezoao odgovarajuće riječi i slike (npr. zadržavanje riječi u radnoj memoriji sve dok se ne prikaže odgovarajuća slika). To uzrokuje preopterećenje radne memorije i škodi procesu usvajanja znanja. Stoga, verbalni prikaz riječi smanjuje efekt modaliteta i omogućava optimalno vremensko usklađivanje i prostorno povezivanje riječi i slika kako bi se uklonio efekt podijeljene pažnje (Stiller, K. D., 2007).

Načelo modaliteta utvrđeno je u 53 od 61 eksperimentalnog istraživanja (Mayer, R. E., 2014c, prema Benassi, V. A., Overson, C. E. i Hakala, C. M., 2014), u kojima su ispitanici postigli bolje rezultate na *transferu* znanja u procesu učenja različitih sadržaja u računalnom (snimljeni govor ili tekst na zaslonu računala) ili tiskanom obliku (snimljeni govor ili tiskani tekst): geometrijski problemi (Mousavi, S. Y., Low, R. i Sweller, J., 1995), elektronika (Tindall-Ford, S. K., Chandler, P. i Sweller, J., 1997, prema Stiller, K. D., 2007), matematika (Jeung, H. J., Chandler, P. i Sweller, J., 1997, prema Mayer, R. E. i Alexander, P. A., 2011), rad automobilskih kočnica (Mayer, R. E. i Moreno, R., 1998), električni inženjering (Kalyuga, S., Chandler, P. i Sweller, J., 1999, 2000), formiranje munje (Mayer, R. E. i Moreno, R., 1998; Moreno, R. i Mayer, R. E., 1999; Craig, S. D., Gholson, B. i Driscoll, D. M., 2002), botanika (Moreno, R. i sur., 2001), matematički problemi (Atkinson, R. K., 2002), igre iz botanike (Moreno, R. i Mayer, R. E., 2002a, prema Mayer, R. E. i Alexander, P. A., 2011), čitanje grafikona (Leahy, W., Chandler, P., Sweller, J., 2003, prema Mayer, R. E. i Alexander, P. A., 2011), instrukcijski dizajn (Tabbers, H., Martens, R. i van Merriënboer, J. J. G., 2004), biologija (Harskamp, E. i sur., 2007, prema Mayer, R. E. i Alexander, P. A., 2011), simulacija zrakoplova (O'Neil, H. F. i sur., 2000, prema Mayer, R. E. i Alexander, P. A., 2011) i dr.

Kao i kod drugih načela KTMUZ-a i ovdje postoje granični uvjeti za primjenu načela modaliteta, jer postoje situacije u kojima će upotreba pisanog teksta biti učinkovitija u odnosu na govorenu riječ, te poboljšati razumijevanje sadržaja: (1) kada verbalna informacija sadrži tehničke termine; (2) kada je verbalna informacija reproducirana na stranom jeziku; (3) kada je verbalna informacija prikazana u predugačkim segmentima koje nije moguće zadržati u radnoj memoriji (Mayer, R. E., 2009, prema Benassi, V. A., Overson, C. E. i Hakala, C. M., 2014; Mayer, R. E., Pilegard, C., 2014, prema Benassi, V. A., Overson, C. E. i Hakala, C. M., 2014). Istraživanja su pokazala da načelo modaliteta ima najveći učinak kada je poruka konceptualno složena (Tindall-Ford, S. K., Chandler, P. i Sweller, J., 1997, prema Stiller, K. D., 2007), te kada je prikaz poruke vremenski brz (ograničeno i fiksirano vrijeme učenja) i nije pod kontrolom primatelja poruke, već sustava (simultani prikaz riječi i slika) (Tabbers, H., Martens, R. i van Merrienboer, J. J. G., 2004; Guan, Y.-H., 2009).

2.2.7.6 Načelo zalihosnosti

Načelo zalihosnosti pretpostavlja da primatelji poruke bolje usvajaju sadržaj prezentiran animacijom i govorenim tekstom (naracija), nego sadržaj prezentiran animacijom, govorenim tekstom i pisanim tekstom (tekst na računalnom zaslonu) (Mayer, R. E., 2001, 2005; Mayer, R. E., 2009, prema Mayer, R. E. i Alexander, P. A., 2011).

Načelo se temelji na pretpostavci po kojoj ljudi posjeduju ograničeni kapacitet za obradu vizualnih informacija i ograničeni kapacitet za obradu verbalnih informacija, gdje se vizualno/slikovni kanal koristi za obradu riječi (pisani tekst) i slika (animacije), a slušno/verbalni kanal za obradu govorene riječi (naracije). Prema KTMUZ proces konstrukcije znanja obuhvaća odabir, organizaciju i integraciju relevantnih vizualnih i verbalnih informacija iz multimedijske poruke. Taj je proces podložen ograničenjima spoznajnih resursa za obradu informacija i može se poremetiti u slučaju preopterećenja vizualnog ili verbalnog kanala. Ako je multimedijska poruka oblikovana prema pet prethodno opisanih načela, a istovremeno sadrži prikaz slike, pisane riječi i naracije, ljudski sustav za obradu informacija može postati kognitivno preopterećen na dva načina:

- (1) Kad se riječi prikazu vizualno kao pisani tekst na zaslonu računala – riječi i slike simultano ulaze u vizualno/slikovni kanal kroz osjetilo vida (oči) gdje se međusobno natječu za ograničene spoznajne resurse u obradi informacija što uzrokuje preopterećenje vizualne memorije. U tom slučaju primatelji poruke nisu u stanju

izgraditi referentne veze između vizualnog i verbalnog prikaza čime se narušava proces konstrukcije znanja.

- (2) Kad se verbalna informacija prikaže i vizualno i slušno – primatelji poruke mogu uložiti i potrošiti kognitivne resurse na mentalno usklađivanje dva informacijska toka (tekst i naracija). Zbog toga neće imati na raspolaganju dovoljno resursa za obradu animacije i mentalno povezivanje animacije s naracijom, što čini ključan proces za smisljeno usvajanje znanja.

Stoga, najučinkovitiji način prikaza verbalnog sadržaja jest putem verbalnog kanala (govoreni tekst), jer se u tom slučaju izostavljeni pisani tekst ne natječe sa slikama za spoznajne resurse u vizualnom kanalu i ne dolazi do povećavanja sadržajno irelevantnog kognitivnog opterećenja radne memorije.

Načelo zalihosnosti utvrđeno je u svih 16 eksperimentalnih istraživanja (Mayer, R. E., 2014c, prema Benassi, V. A., Overson, C. E. i Hakala, C. M., 2014), u kojima su ispitanici postigli bolje rezultate na *transferu* znanja u procesu učenja različitih znanstvenih sadržaja prikazanih u računalnom obliku: električni inženjering (Kalyuga, S., Chandler, P. i Sweller, J., 1999, 2000), računalne simulacijske igre iz botanike (Moreno, R. i Mayer, R. E., 2002a, prema Mayer, R. E. i Alexander, P. A., 2011), formiranje munje (Mayer, R. E., Heiser, H. i Lonn, S., 2001; Craig, S. D., Gholson, B. i Driscoll, D. M., 2002; Moreno, R. i Mayer, R. E., 2002b; Austin Stalcup, K. A., 2005), ljudska memorija (Jamet, E. i Le Bohec, O., 2007) ili tiskanom obliku – geometrijski zadatci (Mousavi, S. Y., Low, R. i, Sweller, J., 1995) i temperaturni grafikoni (Leahy, W., Chandler, P., Sweller, J., 2003, prema Mayer, R. E. i Alexander, P. A., 2011).

Dakle, načelo zalihosnosti ima najveći učinak kada je tekst na računalnom zaslonu smješten na dnu zaslona u formi natpisa te sadržajno ekvivalentan naraciji (cjelovita reprodukcija naracije). Međutim, brojni autori su istaknuli granične uvjete prema kojima se načelo može reducirati ili čak imati obrnuti učinak (prikaz teksta pomaže u konstrukciji znanja), (Mayer, R. E., 2009, prema Kassim, H., 2011; Mayer, R. E. i Johnson, C. I., 2008; Yue, C. L., Ligon Bjork, E. i Bjork, R. A., 2013; Mayer, R. E., Fiorella, L., 2014, prema Benassi, V. A., Overson, C. E. i Hakala, C. M., 2014): (1a) tekst na računalnom zaslonu treba sažeti (dvije do tri riječi) s naglaskom na ključne elemente opisane u naraciji čime se potiče esencijalna obrada informacija bez stvaranja sadržajno irelevantnog kognitivnog opterećenja; (1b) tekst treba smjestiti uz odgovarajuću ilustraciju radi minimiziranja sadržajno irelevantnog kognitivnog opterećenja tijekom vođenja pažnje primatelja poruke prema

sadržajno relevantnim aspektima grafike; (2) naraciju treba prikazati prije teksta; (3) tekst i naraciju može se prikazati simultano ako prikaz ne uključuje grafiku, te ako je naracija vremenski kraćeg trajanja; (4) riječi nisu na materinjem jeziku; (5) primatelj poruke ima poteškoća sa sluhom.

2.2.7.7 Načelo individualnih razlika

Na temelju prethodno opisanih šest načela moguće je oblikovati učinkovitu multimedijску poruku u svrhu unaprjeđenja zapamćivanja i razumijevanja sadržaja. Međutim, načelo individualnih razlika postavlja pitanje stupnja učinkovitosti multimedijске poruke u odnosu na dva čimbenika: razinu predznanja i prostorne sposobnosti primatelja poruke (Mayer, R. E., 2001). Prema KTMUZ, razumijevanje sadržaja temelji se na sposobnosti povezivanja odgovarajućih vizualnih i verbalnih prikaza koji se istovremeno nalaze u radnoj memoriji. Kod loše oblikovane multimedijске instruktivne poruke (npr. riječi nisu prikazane s odgovarajućim slikama), postoji velika vjerojatnost da će primatelji s visokom razinom predznanja biti sposobni upotrijebiti svoje predznanje iz dotične domene kako bi nadoknadili loš dizajn, odnosno izgraditi vizualne i verbalne prikaze samo iz riječi, te ih istovremeno zadržati u radnoj memoriji. Nasuprot tome, primatelji s niskom razinom predznanja to neće biti u stanju učiniti. Kod dobro oblikovane poruke i jedni i drugi primatelji će biti sposobni razumjeti sadržaj, jer će moći izgraditi vizualne i verbalne prikaze te ih držati u radnoj memoriji u isto vrijeme. Iz tih razloga proizlazi kako će primatelji s visokom razinom predznanja bolje razumjeti sadržaj iz loše oblikovane poruke, dok će oni s niskom razinom predznanja imati najviše koristi od primjene načela oblikovanja multimedijске poruke.

Nadalje, kako su multimedijске instruktivne poruke po svojoj prirodi verbalnog i vizualnog karaktera, prostorna sposobnost je vrlo važan čimbenik u multimedijском usvajanju znanja, jer primatelji poruke moraju biti u stanju oblikovati, zadržati i koristiti mentalne slike (Carroll, J. B., 1993, prema Mayer, R. E. i Sims, V. K., 1994, str. 392). Jedan od aspekata prostorne sposobnosti, relevantan za usvajanje znanja iz pokretnih slika ili animacija, jest prostorna vizualizacija odnosno sposobnost mentalne rotacije ili preklapanja objekata u dvjema ili trima dimenzijama, te zamišljanje promjenjivih konfiguracija objekata koje proizlaze iz takvih manipulacija (Mayer, R. E. i Sims, V. K., 1994, str. 392).

Loše oblikovana multimedijска poruka rezultat je narušavanja nekog od načela, kao što je npr. načelo vremenske usklađenosti. Ako su riječi (naracija) i slike (animacija) vremenski nekoordinirani, primatelji s boljom i slabijom prostornom sposobnosti će imati poteškoća u

izgradnji odgovarajućeg vizualnog i verbalnog prikaza, te njihova zadržavanja u radnoj memoriji u isto vrijeme. Visoka razina prostorne sposobnosti neće biti dovoljna za izgradnju vizualnih prikaza iz riječi, posebno kada se verbalni opis temelji na znanju iz određene domene. Zbog toga, pretpostavka je kako će i jedni i drugi primatelji postići jednake rezultate u razumijevanju sadržaja kod loše oblikovane poruke. Međutim, kod dobro oblikovane poruke (simultani prikaz), primatelji s boljom prostornom sposobnosti su u mogućnosti alocirati dovoljno kognitivnih izvora za izgradnju odgovarajućeg vizualnog i verbalnog prikaza te mentalnih veza između njih. Nasuprot tome, primatelji s lošijom prostornom sposobnosti moraju posvetiti više kognitivnog napora za izgradnju i zadržavanje vizualnih prikaza, zbog čega im ostaje vrlo malo kognitivnog kapaciteta za mentalno povezivanje vizualnog i verbalnog prikaza. Iz tih razloga proizlazi kako će primatelji s boljom prostornom sposobnosti imati više koristi iz dobro oblikovane poruke nego primatelji s lošijom prostornom sposobnosti.

Važno je uočiti razliku u smjeru djelovanja razine predznanja i prostornih sposobnosti. Znanje primatelja nadoknađuje loše oblikovanu poruku, tako da primatelji s dobrim predznanjem mogu razumjeti sadržaj dobro i loše oblikovane poruke, dok primatelji s lošim predznanjem imaju veću korist od dobro nego od loše oblikovane poruke. Nasuprot tome, primatelji s boljom i slabijom prostornom sposobnosti jednako neuspješno usvajaju znanje iz slabo oblikovane poruke, ali primatelji s boljom prostornom sposobnosti imaju veću korist od dobro oblikovane poruke.

Istraživanja su utvrdila da načelo multimedije, načelo prostorne povezanosti i načelo vremenske usklađenosti ovise o individualnim razlikama ispitanika.

Predznanje ispitanika pokazalo se graničnim uvjetom za primjenu načela multimedije u određenoj domeni znanja. Fletcher i Tobias (2005, prema Mayer, R. E., 2005) istaknuli su kako učinkovitost upotrebe riječi i slika može ovisiti o individualnim razlikama ispitanika, kao što su razina predznanja i kognitivni stil. Mayer i Gallini (1990) pokazali su kako dodavanje slike riječima nije značajno unaprijedilo *transfer* znanja kod ispitanika s visokom razinom predznanja, budući da oni posjeduju strategije za vizualizaciju informacija iz tekstualnih sadržaja zbog čega im dodatne ilustracije nisu potrebne. Nasuprot tome, Kalyuga, Chandler i Sweller (1998, 2000, prema Mayer, R. E. i Alexander, P. A., 2011) ustanovili su kako se dodavanje slike riječima pokazalo od značajne pomoći ispitanicima s niskom razinom predznanja koji nisu imali mentalnu sposobnost vizualizacije, te povezivanja slika i riječi. Međutim, nakon što su ispitanici stekli određeno iskustvo, ostvarili su lošije rezultate

usvajajući znanje iz simultanog prikaza riječi i slika, nego samo iz riječi ili samo iz slika. Prema tom efektu (engl. *expertise reversal effect*), instruktivna metoda koja unaprijeđuje razumijevanje sadržaja kod ispitanika s lošim predznanjem može biti neučinkovita ili štetna za ispitanike s dobrim predznanjem (Sweller, J. i sur., 2003; Kalyuga, S., 2005, prema Mayer, R. E., 2005). U nizu istraživanja na području kognitivnih stilova utvrdilo se kako nema dovoljno empirijskih dokaza prema kojima bi verbalno-lingvistički stil ispitanika imao više koristi od slikovnih prikaza, a vizualno-prostorni stil više koristi od verbalnih instrukcija (Massa, L. J. i Mayer, R. E., 2006; Pashler, H. i sur., 2008).

Prema graničnim uvjetima za primjenu načela prostorne povezanosti pokazalo se da načelo ima najveći učinak kod usvajanja kompleksnih sadržaja i interaktivnih multimedijских prikaza (Mayer, R. E., Fiorella, L., 2014, prema Benassi, V. A., Overson, C. E. i Hakala, C. M., 2014), te kod ispitanika s niskom razinom predznanja kojima je prostorna integracija riječi i slika pomogla u izgradnji referentnih mentalnih veza (Ginns, P., 2006, prema Kassim, H., 2011).

U ograničenom broju istraživanja utvrđeni su granični uvjeti za primjenu načela vremenske usklađenosti prema kojima načelo ima najveći učinak kod ispitanika s boljom prostornom sposobnosti (Mayer, R. E. i Sims, V. K., 1994), kod usvajanja sadržaja čiju brzinu prikaza određuje dizajner sustava, a ne korisnik (Mayer, R. E., Fiorella, L., 2014, prema Benassi, V. A., Overson, C. E. i Hakala, C. M., 2014) i kod usvajanja animacijskih prikaza ili segmenata koji su vremenski duljeg trajanja (Moreno, R., i Mayer, R. E., 1999; Mayer, R. E. i sur., 1999). Kod vremenski kraćih slijednih segmenata okvira animacije i naracije smanjuje se sadržajno irelevantno kognitivno opterećenje radne memorije i ispitanik je sposoban izgraditi mentalne veze između vizualnog i verbalnog prikaza, kao i kod simultanog prikaza. Sve dok je animacijski prikaz segmentiran na kraće od 10 sekundi za pojedinačni okvir animacije, načelo vremenske usklađenosti neće imati učinka, odnosno pripadajući narativni segment neće škoditi procesu usvajanja znanja bilo da kasni ili prethodi u odnosu na okvir animacije (Mayer, R. E., 2009, prema Kassim, H., 2011).

2.2.7.8 Načelo signalizacije

Načelo signalizacije pretpostavlja da primatelji poruke bolje usvajaju sadržaj kada prikaz sadrži dodatne signale (engl. *signals*) ili znakove (engl. *cues*) kojima se ističe

organizacijska struktura i sadržaj esencijalnog dijela poruke (Mayer, R. E. i Alexander, P. A., 2011; Mayer, R. E., 2014c, prema Benassi, V. A., Overson, C. E. i Hakala, C. M., 2014).

Primjenom načela signalizacije manipuliraju se vizualno-prostorne karakteristike multimedijskog prikaza kako bi se primateljima poruke pomoglo u odabiru, organizaciji i integraciji informacija u koherentne mentalne strukture (de Koning, B. B. i sur., 2009). Signalizacija verbalnog sadržaja obuhvaća upotrebu uvodnog i zaključnog pregleda, naslova, indikatora funkcije i relevantnosti, tipografskih signala, nabiranja, fraza kojima se upućuje i dr. Signalizacija vizualnog sadržaja obuhvaća upotrebu strelica, „bljeskanja“ (engl. *flashing*) i osvjetljavanja (engl. *spotlighting*) određenih objekata u vizualnom prikazu (de Koning, B. B. i sur., 2007, 2009). Signalizacija proizlazi iz istraživanja na području obrade teksta (de Koning, B. B. i sur., 2009) i izvorno se definira kao „*dodatak nesadržajnog aspekta proze koji ističe određene aspekte semantičkog sadržaja ili aspekte strukture sadržaja*“ (Meyer, B. J. F., 1975, str. 77, prema de Koning, B. B. i sur., 2007). Danas se signalizacija primjenjuje u prikazima sa statičnim ilustracijama (Mautone, P. D. i Mayer, R. E., 2001; Meyer, B. J. F., 1975, prema de Koning, B. B. i sur., 2009) i pokretnim slikama ili animacijama (de Koning, B. B. i sur., 2007), gdje se definira kao „*dodatak nesadržajnih informacija koji usmjeravaju pažnju prema sadržajno važnim aspektima animacije*“ (de Koning, B. B. i sur., 2007, str. 733).

Dakle, signali (engl. *signals*) ili znakovi (engl. *cues*) su nesadržajni elementi multimedijske instruktivne poruke koji ne unose nove informacije niti mijenjaju sadržaj prikaza (Lorch, R. F., 1989, prema de Koning, B. B. i sur., 2009). Njihova je uloga smanjiti prostorno pretraživanje i istaknuti sadržajno relevantne dijelove prikaza u točno određenom vremenskom trenutku (Bétrancourt, M., 2005; Schnotz, W. i Lowe, R. K., 2008, prema de Koning, B. B. i sur., 2009). Time se smanjuje irelevantno sadržajno kognitivno opterećenje (Paas, F., Renkl, A. i Sweller, J., 2003) i omogućuje angažiranje spoznajnih resursa u kognitivne procese koji su ključni za razumijevanje sadržaja i konstrukciju znanja. Prema Mautone i Mayer (2001) uloga signalizacije u procesu konstrukcije znanja promatra se na trima razinama:

- (1) **Uloga signalizacije u vođenju pažnje** – pomaže u odabiru esencijalnih dijelova poruke kako bi primatelj bio sposoban razlučiti relevantne od nerelevantnih informacija. U ovom se slučaju koriste: (1) *naslovi* (engl. *titles*) koji definiraju glavnu temu odjeljka teksta čime se primatelja potiče na prepoznavanje dijelova teksta koji su relevantni za dotičnu temu; (2) *indikator funkcije i relevantnosti* (engl. *function and relevance indicators*), kao što su „*stoga, u sažetku*“ i „*važno je naglasiti*“, koji identificiraju tematski relevantne informacije; (3) *tipografski signali*,

kao što su različiti stilovi fonta (zadebljana slova, kurzivna slova, boje fonta i isticanje teksta (engl. *highlighting*)), koji direktno usmjeravaju pažnju na relevantne riječi vizualno ih ističući u odnosu na preostali dio teksta.

- (2) **Uloga signalizacije u vođenju procesa organizacije znanja** – pomaže u organiziranju informacija u mentalne koherentne predodžbe. U ovom se slučaju koriste: (1) *naslovi* (engl. *headings*) koji pridonose konstrukciji globalne predodžbe teksta označavanjem glavnih koncepata; (2) *signaliziranje nabravanjem* (*prvi, drugi, treći...*) za označavanje globalne strukture teksta (Lorch, R. F., 1989, prema de Koning, B. B. i sur., 2009); (3) *uvodni pregled* (engl. *overview*) i *zaključni pregled* (engl. *review*), koji ističu glavne teme i okvirnu organizaciju teksta (Lorch, R. F., 1989, prema de Koning, B. B. i sur., 2009); (4) sažeci koji ističu glavne ideje teksta; (5) *fraze kojima se upućuje* (engl. *pointer phrases*), kao što je „*zbog toga*“, i *fraze logičkih veza* (engl. *logical connective phrases*), kao što je „*kao rezultat toga*“, koji više djeluju na lokalnoj razini ističući uzročno-posljedične veze između podređenih koncepata (Lorch, R. F., 1989, prema de Koning, B. B. i sur., 2009).
- (3) **Uloga signalizacije u vođenju procesa povezivanja znanja** – pomaže u integraciji mentalnih predodžbi. Upotrebom signalizacije smanjuje se sadržajno irelevantno kognitivno opterećenje zbog čega primatelji ulažu manje spoznajnih resursa u odabiru relevantnih informacija i interpretiranju organizacije teksta, te imaju više dostupnih resursa za proces povezivanja predznanja s novim informacijama.

Istraživanja su pokazala da primjena signalizacije pomaže primateljima poruke u prepoznavanju i obradi esencijalnih informacija iz statičnih multimedijских prikaza (Tversky, B. i sur., 2008). Međutim, signali koji su se pokazali učinkovitima kod statičnih prikaza u nekim slučajevima nemaju isti efekt kada se koriste kod dinamičnih ili animacijskih prikaza (de Koning, B. B. i sur., 2009). Razlog tome je kratkotrajna i prolazna priroda animacija gdje postoji ograničeno vrijeme za percipiranje relevantnih dijelova poruke, te mogućnost odvlačenja pažnje primatelja vizualno istaknutim nerelevantnim promjenama u animaciji. Proces vođenja pažnje je kompleksan utoliko što primatelji trebaju biti svjesni ne samo elemenata koji su označeni, već i vremenskih trenutaka u kojima su označeni (de Koning, B. B. i sur., 2009). U tom slučaju određena vrsta signalizacije (npr. strelice) ne posjeduje dovoljnu preciznost za učinkovito vođenje pažnje kod kraćih i bržih dinamičnih prikaza, jer su procesi percipiranja i odabira relevantnih informacija vremenski ograničeni. Također, signalizacija ostvarena raznim promjenama atributa objekata (boja, položaj, oblik) može

dodatno omesti pažnju primatelja koji neće biti sposobni razlikovati pomoćne signale kao odvojene elemente od sadržaja poruke (de Koning, B. B. i sur., 2009). Iz tih razloga, primjena signalizacije može uzrokovati pogrešne interpretacije uzročno-posljedičnih veza u sadržaju poruke i postaviti veće kognitivne zahtjeve u procesu učenja.

S aspekta perceptivne obrade informacija, Schnotz i Lowe (2008, prema de Koning, B. B. i sur., 2009) istaknuli su dvije značajke koje utječu na percepciju različitih elemenata u animacijskim prikazima: *vizualno-prostorni kontrast* (element se ističe u odnosu na pozadinu zbog jasnih vizualnih atributa, kao što su boja ili oblik) i *dinamični kontrast* (prostorne ili vremenske promjene ističu vidljivost objekata u odnosu na pozadinu). Većina istraživanja pokazala je kako neki objekt može automatski privući pažnju ako se razlikuje od drugih objekata u barem jednom od atributa (npr. boja), ili ako mijenja položaj s jedne lokacije na drugu bez obzira potiču li prikazani pomaci ili narušavaju proces konstrukcije znanja. Kako se oba aspekta mogu pronaći u složenim animacijskim prikazima, oblikovanje signala ili znakova treba se temeljiti na istim svojstvima kako bi učinkovito usmjeravali pažnju prema relevantnim informacijama i time smanjili sadržajno irelevantno kognitivno opterećenje (de Koning, B. B. i sur., 2009).

S aspekta kognitivne obrade informacija, signalizacija se klasificira u: (1) selekcijske znakove; (2) organizacijske znakove i (3) znakove za povezivanje, koji korespondiraju s kognitivnim procesima odabira, organiziranja i povezivanja informacija u radnoj memoriji. Seleksijski znakovi pomažu primatelju poruke u odabiru najrelevantnijih elemenata prikaza (npr. promjena tona i visine glasovnog isticanja ključnih riječi ili fraza u naraciji; upotreba vizualnih grafičkih znakova, kao što su obojane strelice). Organizacijski znakovi (npr. naslovi, upotreba ikona) ističu glavne teme poruke i njihovu organizaciju te pomažu primatelju u identificiranju i organiziranju dijelova predodžbi u koherentnu strukturu. Također, takvi znakovi olakšavaju obradu teksta i poboljšavaju zapamćivanje. Znakovi povezivanja pomažu u izgradnji mentalnih veza između (npr. kodirnje bojom, engl. *color coding*) i unutar (npr. upotreba kontrasta, engl. *color contrast*) organiziranih dijelova predodžbi, te njihova povezivanja u funkcionalni mentalni model (de Koning, B. B. i sur., 2009). Dije se u dvije kategorije: (1) signalizacija za isticanje odnosa između dva elementa unutar pojedinačnog prikaza; (2) signalizacija radi privlačenja pažnje prema povezanim elementima iz različitih prikaza. Pri tome se koriste razne tehnike: „bljeskanje“ sadržajno povezanih elemenata (Craig, S. D., Gholson, B. i Driscoll, D. M., 2002, prema de Koning, B. B. i sur., 2009), označavanje međusobno povezanih elemenata istom bojom radi uspostavljanja veza između tekstualnih i vizualnih informacija (Kalyuga, S., Chandler, P. i

Sweller, J., 1999) i upotreba neverbalnih znakova za usmjeravanje pažnje prema povezanim elementima (Lusk, M. M. i Atkinson, R. K., 2007, prema de Koning, B. B. i sur., 2009).

Načelo signalizacije utvrđeno je u 25 od 29 eksperimentalnih istraživanja (Mayer, R. E., 2014c, prema Benassi, V. A., Overson, C. E. i Hakala, C. M., 2014), u kojima su ispitanici postigli bolje rezultate na *transferu* znanja u procesu učenja različitih znanstvenih sadržaja prikazanih u tiskanom ili računalnom obliku: geometrija (Jeung, H.-J., Chandler, P., i Sweller, J., 1997, prema Kassim, H., 2011), polijetanje zrakoplova (Mautone, P. D. i Mayer, R. E., 2001), geografija (Mautone, P. D. i Mayer, R. E., 2007, prema Kassim, H., 2011), rad kardiovaskularnog sustava (de Koning, B. B. i sur., 2007; Scheiter, K. i Eitel, A., 2010), način rada klavira (Boucheix, J-M. i Lowe, R.K., 2010; Boucheix, J-M. i sur., 2013), način rada mlaznog pogona (Ozcelik, E., Arslan-Ari, I. i Cagiltay, K., 2010), instrukcijski dizajn (Tabbers, H., Martens, R. i van Merrienboer, J. J. G., 2004) i dr.

Prema graničnim uvjetima, načelo signalizacije ima najveći učinak kod primatelja poruke s niskom razinom predznanja, kod kompleksnih sadržaja i umjerene upotrebe signala ili znakova (Mayer, R. E., 2014c, prema Benassi, V. A., Overson, C. E. i Hakala, C. M., 2014).

2.2.7.9 Načelo animacije i interaktivnosti

Dinamični vizualni prikaz (engl. *dynamic visual display*) definira se kao prikaz bilo kakve vrste grafičkog pokreta unutar medijske instrukcije (Park, O. i Hopkins, R., 1993), bilo da se radi o filmu kao prikazu pokreta objekata iz predmetnog okruženja, računalnoj animaciji kao prikazu pokreta umjetno stvorenih objekata (Mayer, R. E. i Moreno, R., 2002, str. 88) ili simulaciji. Računalna animacija, kao jedna vrsta dinamičnog vizualnog prikaza, jest „*bilo koja aplikacija koja generira uzastopni niz okvira (engl. frame), gdje je svaki slijedeći okvir alternacija prethodnog*“, čime se postiže vizualna iluzija pokreta jednog ili više objekata u prostoru i vremenu (Bétrancourt, M. i Tversky, B., 2000, str. 5). Pri tome, generirani niz okvira može odrediti instrukcijski dizajner ili korisnik. Općenito, komponente grafičkih objekata instrukcijske animacije mogu proći kroz tri vrste promjena (Lowe, R. K., 2003, str. 159):

- (1) Promjene oblika ili transformacije (engl. *transformations*) koje uključuju izmjene objekata s obzirom na njihova svojstva, kao što su veličina, oblik, boja i tekstura.

- (2) Promjene položaja ili translacije (engl. *translations*) koje uključuju pomicanje svih komponenti objekta s jedne lokacije na drugu.
- (3) Promjene inkluzije ili prijelazi (engl. *transitions*) koje uključuju „pojavljivanje“ ili „nestajanje“ objekta (potpuno ili djelomično) u određenim fazama i dijelovima animacijskog prikaza.

U sklopu obrazovnih multimedijских okruženja ističu se tri različita načina upotrebe animacija (Bétrancourt, M., 2005, prema Mayer, R. E., 2005, str. 288-289):

- (1) Kao podrška za vizualizaciju i formiranje mentalnog prikaza dinamičnih fenomena koje nije moguće izravno proučavati (npr. rad kardiovaskularnog sustava (de Koning, B. B. i sur., 2007), vremenske promjene (Lowe, R. K., 2003, 2005)); koje nije moguće realizirati u nastavnom okruženju (preskupi ili preopasni) i koji su apstraktni i simbolični po svojoj prirodi (npr. način rada strujnog kruga, prikazi fizikalnih sila, izvođenje računalnih algoritama (Narayanan, N. H. i Hegarty, M., 2002), statistički koncepti (Bodemer, D. i sur., 2004; Ma, Y., Hung, W-C., 2007)).
- (2) Kao način formiranja kognitivnog konflikta upotrebom više različitih animacijskih prikaza istog znanstvenog fenomena radi pronalaženja ispravnog rješenja.
- (3) Kao mogućnost interaktivnog istraživanja fenomena iz različitih područja, kao što su biologija, matematika, mehanika, meteorologija, fizika i računalne znanosti (Tversky, B., Morrison, J. B. i Bétrancourt, M., 2002).

Iako su do sada provedena mnoga istraživanja učinkovitosti upotrebe animacijskih prikaza, vrlo se malo zna o njihovoj kognitivnoj obradi (Lowe, R.K., 2004; Chandler, P., 2004), te kako ih prilagoditi ljudskim kognitivnim sposobnostima upotrebom instrukcijskog dizajna radi smislenog usvajanja znanja (de Koning, B. B. i sur., 2007). To uključuje prilagodbu sa stajališta tehnologije (upotreba fizičkih sustava za prijenos sadržaja), semiotičke razine (verbalni i slikovni sustavi za prikaz znanja) koja razmatra „ono što se mijenja“ u animaciji i „način na koji se mijenja“ (npr. pokret, transformacija, promjena točke promatranja), te osjetilne razine (sposobnost obrade sadržaja pomoću slušnog i vizualnog kanala), (Schnotz, W. i Lowe, R. K., 2003). U većini istraživanja instrukcijska animacija pokazala se jednako učinkovitom ili čak manje učinkovitom u usporedbi sa statičnim slikovnim prikazima (Bétrancourt, M. i Tversky, B., 2000; Hegarty, M., Narayanan, N. H. i Freitas, P., 2002; Narayanan, N. H. i Hegarty, M., 2002; Tversky, B., Morrison, J. B. i Bétrancourt, M., 2002; Hegarty, M., Kriz, S. i Cate, C., 2003; Mayer, R. E., Hegarty, M.,

Mayer, S. i Campbell, J., 2005; Lowe, R. K., 2003; Tversky, B. i sur., 2008). Prednost instrukcijske animacije (Lin, L. i Atkinson, R. K., 2011) utvrđena je samo u određenim uvjetima (Höffler, T. N. i Leutner, D., 2007; Wong, A. i sur., 2009; Ayres, P., i sur, 2009; Ng, H. K., 2014), zatim u situacijama kada su animacijski prikazi sadržavali više informacija od statičnih prikaza (Rieber, L. P., 1990a, 1991) ili dodatne faktore koji su olakšavali proces učenja, kao što su interaktivnost te mogućnost predviđanja ponašanja mehaničkih sustava i procesa (Byrne, M. D., Catrambone, R. i Stasko, J. T., 1999). Tversky, Morrison i Bétrancourt (2002) proučili su niz istraživanja u kojima se instrukcijska animacija upotrijebila za poučavanje kompleksnih sustava na području mehanike, biologije, fizike i računalstva, te istaknuli kako upotreba animacija može biti učinkovita, ali ne nužno i superiornija u odnosu na statični ekvivalent, ako instrukcijski dizajn slijedi načelo dosljednosti (engl. *Congruence Principle*) i načelo razumijevanja (engl. *Apprehension Principle*), (Bétrancourt, M., 2005, prema Mayer, R. E., 2005, str. 294-295). Höffler i Leutner (2007) izvršili su metaanalizu od 26 istraživanja između 1973.-2003. godine usporedivši instrukcijske animacijske (video prikazi, računalne animacije) i statične slikovne prikaze s područja biologije, fizike, kemije, matematike i dr. Autori su identificirali niz mogućih faktora odgovornih za učinkovito usvajanje znanja iz animacija, pri čemu su ključni faktori bili stjecanje proceduralnog i motoričkog znanja te upotreba opisne (engl. *representational*) vrste animacije. Opisna animacija u svom prikazu sadrži željeni ishod učenja odnosno prikazani pokreti eksplicitno se odnose na sadržaj koji primatelj poruke treba usvojiti.

Dugogodišnji rezultati pokazali su kako istraživačko pitanje „*Kada i kako se animacija treba koristiti kako bi unaprijedila proces razumijevanja?*“ (Bétrancourt, M., 2005, prema Mayer, R. E., 2005, str. 288) treba primarno usmjeriti na analizu i učinke instrukcijskog dizajna različitih vrsta dinamičnih vizualnih prikaza na različite vrste sadržaja za učenje (Hegarty, M., 2004, Schnotz, W. i Rasch, T., 2005). To je rezultiralo postavljanjem dva uvjeta prema kojima se može postići učinkovita upotreba animacija (Bétrancourt, M., 2005, prema Mayer, R. E., 2005, str. 293):

- (1) Kada opisani koncept ili fenomen uključuje promjene u vremenu čije prijelaze primatelj poruke nije u stanju odrediti na temelju statičnih slikovnih prikaza.
- (2) Kada primatelj poruke nema predznanja u određenoj domeni, ima slabije sposobnosti mentalne vizualizacije te nije u stanju samostalno kreirati mentalni model opisanog fenomena (engl. *enabling function*) ili je pak suočen s vrlo visokim kognitivnim opterećenjem pri čemu animacijski prikaz pruža vanjsku podršku

mentalnim simulacijskim procesima i smanjuje kognitivno opterećenje (engl. *facilitating function*) (Schnotz, W. i Rasch, T., 2005, str. 48.).

Na temelju sveopćih rezultata istraživanja postavljeno je pet temeljnih načela oblikovanja instrukcijske animacije (uz načela modaliteta, signalizacije, prostorne povezanosti i vremenske usklađenosti), radi unaprjeđenja razumijevanja sadržaja (Bétrancourt, M., 2005, prema Mayer, R. E., 2005, str. 294-295): *načelo dosljednosti, načelo razumijevanja, načelo interaktivnosti, načelo vođenja pažnje i načelo fleksibilnosti.*

(1) Načelo dosljednosti (engl. *Congruence Principle*)

Načelo dosljednosti ističe kako struktura i sadržaj vanjskih animacijskih prikaza trebaju korespondirati strukturi i sadržaju unutarnjih prikaza (Tversky, B., Morrison, J. B. i Bétrancourt, M., 2002, str. 249). Iz tih razloga, vanjski dinamični prikazi mogu biti namjerno iskrivljeni na razne načine ako to pomaže promatraču u razumijevanju kauzalnih odnosa nekog fenomena. Iskrivljenja se mogu odnositi na: (1) usporavanje ili ubrzavanje procesa; (2) prikazivanje objekta iz različitih perspektiva; (3) naglašavanje sadržajno važnih dijelova kako bi se privukla pažnja promatrača (Lowe, R. K., 2003); (4) kombiniranje više individualnih dinamičnih prikaza istog fenomena različitih po informaciji koju prenose i procesu koji objašnjavaju i to u slučaju kada jedan dinamični prikaz nije dovoljan za učinkoviti prijenos sadržaja (Ainsworth, S. E. i Van Labeke. N., 2004).

(2) Načelo razumijevanja (engl. *Apprehension Principle*)

Prema načelu razumijevanja primatelj poruke treba ostvariti ispravnu percepciju i razumijevanje strukture i sadržaja animacijskih prikaza. To je moguće postići uvođenjem interaktivne navigacije za kontrolu brzine. Kada su dinamični vizualni prikazi dovoljno spori i jasni, promatrač može percipirati pokrete objekata, prostorne i vremenske promjene fenomena te kauzalne odnose između segmenata i niza događaja. Razumijevanje prikazanih promjena ostvaruje se upotrebom načela signalizacije ili vođenjem pažnje promatrača prema sadržajno relevantnim dijelovima animacije. Pri tome, iz animacije se uklanjaju svi perceptivno istaknuti aspekti koji nisu korisni za razumijevanje sadržaja (Tversky, B., Morrison, J. B. i Bétrancourt, M., 2002) ili koji se nalaze na odvojenim lokacijama i istovremeno natječu za vizualnu pažnju (Schmidt-Weigand, F., 2005).

Za razliku od statičnih slikovnih prikaza koji sadrže vizualno-prostorne informacije, animacija dodatno obuhvaća i vremensku dimenziju (Schnotz, W. i Lowe, R. K., 2008, prema de Koning, B. B. i sur., 2009). Statični prikazi služe kao vanjska pomoćna memorija u procesu učenja i nude mogućnost proučavanja sadržaja u više navrata. Situacija je malo složenija kod dinamičnih vizualnih prikaza koji su po svojoj prirodi kratkotrajni i prolazni (engl. *transience*), te se koriste za prikaz dinamičnih koncepata, kao što su prostor, veličina, udaljenost, pokret, akceleracija i dr. Perceptivna i kognitivna obrada informacija potrebna za postizanje učinkovitog razumijevanja dinamičnih prikaza može biti prezahtjevna za primatelje poruke (Amadiou, F., Mariné, C. i Laimay, C., 2011), jer uzrokuje visoko sadržajno irelevantno kognitivno opterećenje. Kod dinamičnih prikaza koji nisu interaktivni i odvijaju se određenom konstantnom brzinom, ne postoji mogućnost povratka na prethodne okvire, što znači da jednom percipirani okvir u sljedećem trenutku više nije vidljiv. Kognitivna obrada takvih prikaza zahtijeva pamćenje i zadržavanje trenutno prikazanih informacija u radnoj memoriji radi povezivanja s novim informacijama, te integriranje novih informacija sa postojećim znanjem iz dugoročne memorije. To postavlja velike kognitivne zahtjeve na radnu memoriju (Schmidt-Weigand, F., 2005; Hegarty, M., 2004) i može uzrokovati poteškoće u procesu integracije kada su različiti elementi prikaza raspršeni u vremenu (de Koning, B. B. i sur., 2009). Dodatno kognitivno opterećenje nastaje ako se unutar istog prikaza istovremeno mora posvetiti pažnja većem broju elemenata koji se pomiču s jedne lokacije na drugu i sadrže promjene s obzirom na različite attribute (boja, oblik, orijentacija) (de Koning, B. B. i sur., 2009). Iako dinamični aspekti objekata (promjene oblika, položaja i prijelaza) predstavljaju jedan od najučinkovitijih načina privlačenja pažnje, primatelji u većini situacija imaju poteškoća u usmjeravanju svoje pažnje na relevantne dijelove prikaza. Iz tih razloga instrukcijski dizajneri imaju zadatak oblikovati multimedijску poruku kojom će se pažnja primatelja u točno određenom vremenskom trenutku usmjeriti prema esencijalnim dijelovima poruke (Schnotz, W. i Lowe, R. K., 2008, prema de Koning, B. B. i sur., 2009). Na taj se način primateljima pomaže u odabiru, organizaciji i integraciji informacija u koherentne mentalne strukture znanja ili mentalne modele (Hegarty, M., 2004, Lowe, R. K., 2003).

(3) Načelo interaktivnosti (engl. *InteractivityPrinicple*)

Načelo interaktivnosti obuhvaća kontrolu brzine (nižeg i višeg stupnja) i smjera izmjene niza okvira animacije, te djelovanje na događaje unutar okvira modifikacijom određenih parametara od strane primatelja poruke. U tom slučaju animacija prelazi u simulaciju

dinamičnog sustava i otvara mogućnost predviđanja rada sustava kroz proces mentalne simulacije (Narayanan, N. H. i Hegarty, M., 2002).

Kontrola brzine nižeg stupnja može se realizirati upotrebom interakcije „Nastavi“ (engl. „Resume“). Promjena brzine animacijskog prikaza određuje broj elemenata informacija po jedinici vremena kojima promatrač posvećuje pažnju i kognitivno obrađuje u svrhu razumijevanja sadržaja (de Koning, B. B. i sur., 2011). Smanjenjem brzine dobiva se više vremena za detaljnim proučavanjem prikaza i obradom veće količine informacija, te mogućnost stvaranja mentalnih predodžbi dijelova prikaza i njihova povezivanja u integrirani kauzalni mentalni model (Meyer, K., Rasch, T. i Schnotz, W., 2010, prema Koning, B. B. i sur., 2011). Povećanjem brzine ista se količina informacije prikazuje u manje vremena što prisiljava promatrača na brži odabir informacije te zahtjeva trenutnu kognitivnu obradu. U tom slučaju, može doći do kognitivnog preopterećenja radne memorije, perceptivnih propusta i samo djelomične obrade informacija, jer je promatrač imao na raspolaganju malo ili nimalo vremena te nedovoljno dostupnih kognitivnih izvora radne memorije za povezivanje prethodno i trenutno prikazanih informacija (Mayer, R. E. i Chandler, P., 2001; Ayres, P. i Paas, F, 2007, prema de Koning, B. B. i sur., 2011).

U svrhu lakše konceptualizacije načina rada sustava korisniku se može pružiti mogućnost upotrebe vlastite (engl. *user-paced control*) ili računalno predefinirane (engl. *computer-paced control*) segmentacije animacijskih prikaza umetanjem stanki nakon svake glavne faze animacije. Mayer i Chandler (2001) ustanovili su prednost upotrebe stanki u odnosu na kontinuirani tijek animacije, gdje su korisnici imali djelomičnu ili potpunu kontrolu nad brzinom izmjene okvira animacije. Međutim, istraživanja su pokazala kako u većini slučajeva neiskusni korisnici zbog nedovoljno znanja nisu u stanju identificirati tematski najvažnije dijelove animacije niti učinkovito koristiti kontrolu brzine (Lowe, R. K., 2003). Kontrola animacijskih prikaza višeg stupnja (tradicionalne VCR funkcije) treba imati odgovarajuće sučelje koje neće uzrokovati irelevantno kognitivno opterećenje odvrćanjem pažnje promatrača od tematski važnih dijelova animacije. To zahtijeva posjedovanje metakognitivnih vještina za istovremenu upotrebu interakcije i praćenja vlastitih kognitivnih izvora koje treba posvetiti određenoj fazi animacije (Mayer, R. E., 2005).

(4) Načelo vođenja pažnje (engl. *Attention-Guiding Principle*)

Ovo načelo ističe važnost instrukcijskog vođenja pažnje promatrača (Park, O. i Hopkins, R., 1993; Rieber, L. P., 1990b), kako ne bi došlo do perceptivnih propusta ključnih promjena u prikazu poruke važnih za razumijevanje sadržaja. To obuhvaća lociranje,

ekstrakciju i povezivanje sadržajno relevantnih informacija iz prikaza objekata ili fenomena te njihovih dinamičnih karakteristika radi uspješne konstrukcije pokretljivog dinamičnog mentalnog modela (Ng, H. K., 2014). Lowe (2003) ustanovio je kako neiskusni primatelji poruke nisu u stanju razlikovati između tematski relevantnih i nerelevantnih karakteristika u prikazu sadržaja pri čemu je njihova pažnja počivala na perceptivno istaknutim, upadljivim i tematski nerelevantnim promjenama. U tom slučaju, promatrač ignorira suptilnije elemente prikaza koji su važni za razumijevanje sadržaja i konstruira necjeloviti i nefunkcionalni dinamični mentalni model (Ng, H. K., 2014).

(5) Načelo fleksibilnosti (engl. *Flexibility Principle*)

Kako nije moguće predvidjeti razinu predznanja primatelja poruke, prema načelu fleksibilnosti radi poštovanja individualnih razlika, multimedijaska instruktivna poruka treba sadržavati mogućnost uključivanja i isključivanja animacijskih prikaza. Pri tome, instrukcijska animacija treba biti precizno opisana kako bi se izbjegla redundantnost informacija između statičnog i animacijskog prikaza.

2.3 Model kognitivnog procesa multimodalnog razumijevanja

Autori Narayanan i Hegarty (2002) razvili su *model kognitivnog procesa multimodalnog razumijevanja* (engl. *cognitive process model of multimodal comprehension*) kojim se prikazuje proces usvajanja znanja iz multimedijjskih prikaza u domeni računalnih algoritama i mehaničkih uređaja. *Model* se razvio na temelju znanstvenih istraživanja iz kognitivne psihologije ljudsko-računalne interakcije, dijagramskog rasuđivanja i obrade teksta. Inicijalna verzija *modela* opisivala je proces razumijevanja sadržaja iz područja dinamičnih mehaničkih sustava upotrebom multimodalnih prikaza (tekst i dijagrami), (Hegarty, M., Narayanan, N. H. i Freitas, P., 2002, prema Narayanan, N. H. i Hegarty, M., 2002). Prema *modelu*, sadržaj i struktura, prije nego interaktivnost i dinamika prikaza, čine ključne faktore za učinkovito razumijevanje i usvajanje znanja. Proces razumijevanja promatra se kao niz kognitivnih faza tijekom kojih korisnik stvara dinamični mentalni model promatranog sustava, objekta ili situacije na temelju predznanja i multimedijjskih prikaza. Konstrukcija dinamičnog mentalnog modela obuhvaća: (1) proces raščlanjivanja sustava ili računalnog algoritma na jednostavnije funkcionalne komponente; (2) dohvaćanje relevantnog predznanja o raščlanjenim komponentama iz dugoročne memorije; (3) kognitivno kodiranje prostornih i semantičkih veza između komponenti radi izgradnje statičnog mentalnog modela; (4) izgradnju uzročno-posljedičnih veza između komponenti sustava ili algoritma radi poticanja mentalne simulacije statičnog modela.

Termin mentalni model odgovara kauzalnim mentalnim modelima rasuđivanja u određenoj domeni znanja (Gentner, D. i Stevens A., 1983, prema Markman, A. B. i Gentner, D., 2001), gdje su dijelovi mentalnih predodžbi ili modela ekvivalentni komponentama prikazanog sustava ili algoritma. Kauzalni mentalni model je „izvršiv“ (engl. *runnable*), jer sadrži informacije koje omogućuju korisniku mentalno simuliranje i predviđanje rada sustava ili algoritma. Učinkovitost konstrukcije dinamičnog modela ovisi o adekvatnom instrukcijom dizajnu multimedijjskog prikaza, kognitivnim vještinama razumijevanja teksta, prostornim sposobnostima povezivanja informacija iz teksta i slika (Hegarty, M. i Just, M. A., 1993; Hegarty, M. i Sims, V. K., 1994), te kodiranju i interpretaciji informacija iz grafičkih prikaza (Hegarty, M. i Kozhevnikov, M., 1999, prema Narayanan, N. H. i Hegarty, M., 2002). Iako se faze procesa razumijevanja prikazuju slijedno korisnik ima mogućnost mijenjati njihov poredak kako bi detaljno razradio mentalni model.

Smjernice oblikovanja multimedijjskih prikaza *modela* dosljedne su osnovnim načelima KTMUZ-a: načelo multimedije, načelo prostorne povezanosti, načelo vremenske usklađenosti

i načelo koherentnosti. Međutim, uz navedena načela *model* primjenjuje i dodatnih 6 načela u oblikovanju multimedijiskog prikaza:

- (1) **načelo raščlanjivanja** (engl. *the decomposition principle*) – koristiti signale ili znakove u vizualnim i verbalnim prikazima kao pomoć korisniku u procesu raščlanjivanja mehaničkog sustava ili računalnog algoritma na jednostavnije funkcionalne komponente ili elementarne operacije;
- (2) **načelo predznanja** (engl. *the prior knowledge principle*) – koristiti riječi i slike kao pomoć korisniku u dohvatanju i povezivanju predznanja s vanjskim multimedijским prikazima;
- (3) **načelo koreferencije** (engl. *the co-reference principle*) – koristiti interaktivna i deiktička sredstva u svrhu isticanja zajedničkog nazivnika kada se različite verbalne i vizualne reference u različitim medijima odnose na isti predmet (komponenta sustava ili operacija algoritma);
- (4) **načelo izgradnje fizičkih, uzročnih i logičkih veza** (engl. *the lines-of-action principle*) – koristiti riječi i slike kao pomoć u razumijevanju fizičkih, uzročnih i logičkih veza između komponenti sustava ili operacija algoritma;
- (5) **načelo mentalnog simuliranja ili predviđanja** (engl. *the mental simulation principle*) – koristiti grafiku i interaktivna pitanja kao pomoć u predviđanju ili mentalnom simuliranju rada sustava ili algoritma prije uvida u stvarne vrijednosti;
- (6) **načelo temeljnih zakona** (engl. *the basic laws principle*) na kojima počiva rad sustava ili izvođenje algoritma eksplicitno opisani u multimedijskom prikazu kao pomoćni faktor u procesu razumijevanja sadržaja.

Prema autorima *modela* (Narayanan, N. H. i Hegarty, M., 2002), primjena ovih šest načela oblikovanja postiže veću učinkovitost u apstraktnim domenama znanja, kao što su računalni algoritmi gdje grafički dijagrami i animacije prikazuju vizualizacije apstraktnih procesa, za razliku od konkretnih mehaničkih domena gdje animacije prikazuju procese koji su vidljivi u predmetnom okruženju. Mehanički procesi imaju prostorna i vremenska ograničenja koja se ne smiju narušiti u realističnim animacijskim prikazima. Stoga dizajner ima veću slobodu primjene načela oblikovanja u razvoju vizualizacije algoritama nego mehaničkih procesa.

2.3.1 Računalni algoritmi

Osnovna struktura multimedijskog prikaza kojim se postiže razumijevanje računalnog algoritma prikazana je u tablici 5.

Tablica 5. Osnovna struktura multimedijskog prikaza za konstrukciju dinamičnog mentalnog modela računalnog algoritma (Narayanan, N. H. i Hegarty, M., 2002, str. 20)

| Dio | Opis |
|-----|--|
| 1 | Prvi dio prikaza sadrži opis osnovnih karakteristika računalnog algoritma koristeći sličnu analogiju iz predmetnog okruženja. Analogija se objašnjava upotrebom riječi (koncizno tekstualno objašnjenje) i slika (animacija). Ovaj dio stvara temelje za razumijevanje multimedijških prikaza (koji slijede u idućim fazama), izgradnjom predstavničkih veza s aktivnostima iz predmetnog okruženja koje se izvode na sličan način kao i algoritam. |
| 2 | Drugi dio prikaza oblikovan je da pomogne korisniku u procesu raščlanjivanja računalnog algoritma na elementarne funkcionalne komponente. Proces raščlanjivanja treba omogućiti razumijevanje operacija algoritma iz detaljnog, neformalnog opisa algoritma (pseudojezika) i vođen je predznanjem korisnika o algoritmu i njegovim komponentama, te vizualnim svojstvima vanjskih prikaza (npr. upotreba načela signalizacije). Korisnik izgrađuje predstavničke veze između vizualnih prikaza i simboličkih elemenata (komponenti) identificiranih tijekom procesa raščlanjivanja s postojećim predznanjem, te stvara predodžbe odnosa između različitih elemenata algoritma (razumijevanje izvođenja algoritamskih operacija). Uz pomoć različitih prikaza koji se referiraju na istu komponentu (načelo koreferencije), kao što su simultani prikaz pseudojezika i tekstualnog objašnjenja algoritma, korisnik povezuje elemente između tih prikaza i gradi statični mentalni model algoritma. |
| 3 | Treći dio prikaza oblikovan je da pomogne korisniku u izgradnji logičkih veza između komponenti, odnosno da identificira uzročno-posljedični niz radnji u cjelokupnoj strukturi algoritma kako bi konstruirao dinamični mentalni model. U tu svrhu multimedijška poruka sadrži simultani prikaz od četiri elemenata: (1) animacija algoritma na manjem skupu podataka; (2) pseudojezik algoritma; (3) tekstualni opis okvira animacije; (4) dijaloški okvir s trenutnim vrijednostima podataka nakon izvođenja pojedinačnih algoritamskih operacija. Multimedijška poruka sadrži dva interaktivna elementa: <ul style="list-style-type: none">• Dijaloški okvir s nasumičnim pitanjima za predviđanje koraka izvođenja algoritma koja potiču proces mentalnog simuliranja. Zbog neintuitivne i apstraktne naravi algoritma ova se pitanja postavljaju tek nakon što je korisnik proučio animacijski prikaz osnovnog načina rada algoritma.• Okvir animacije koji prikazuje rad algoritma po dijelovima. Sustav zaustavlja animaciju nakon svakog dijela kako bi korisnik stvorio logički slijed radnji na temelju prethodnih koraka. Korisnik kontrolira razinu animacijske podjele algoritma, od izvođenja pojedinačne naredbe do cjelovitog izvršavanja algoritma bez zaustavljanja. Animirani koraci izvršavanja istaknuti su u pseudojeziku te međusobno sinkronizirani što omogućava izgradnju referentnih veza. |

| | |
|---|--|
| 4 | Četvrti dio prikaza oblikovan je da pomogne korisniku u utvrđivanju konstruiranog dinamičnog mentalnog modela. Sadrži prikaz animacije algoritamskih operacija na većem skupu podataka. Okvir animacije nije podijeljen na dijelove kao u trećem dijelu, ali korisnik i dalje ima mogućnost predviđanja vrijednosti parametara u radu algoritma i njihove usporedbe sa stvarnim vrijednostima. |
| 5 | Peti dio prikaza sadrži niz zadataka s višestrukim izborom (engl. <i>multiple choice</i>), kako bi korisnik procijenio svoje znanje. Pitanja su prediktivne naravi radi daljnjeg poticanja procesa mentalne simulacije. |
| 6 | Šesti dio prikaza obuhvaća objašnjenje temeljnih načela rada algoritma koristeći kombinaciju teksta, statičnih slika i animacija. |

2.3.2 Istraživanja

U nizu od pet eksperimenata u dvije različite domene utvrđena je prednost interaktivnih hipermedijskih prikaza oblikovanih prema *modelu kognitivnog procesa multimodalnog razumijevanja* u odnosu na tradicionalne tiskane prikaze u udžbenicima, računalne multimedijske prikaze i statične tiskane prikaze istog sadržaja (Narayanan, N. H. i Hegarty, M., 2002). Također, istraživanja su pokazala kako statični multimodalni (tiskani) i interaktivni grafički (računalni) prikazi istog sadržaja oblikovani prema *modelu* imaju jednaku učinkovitost u prenošenju informacija, gdje interaktivni elementi i dinamični čimbenici (animacija) nemaju prednost u unaprjeđenju razumijevanja sadržaja naspram statičnih sastavnica poruke. Interaktivni elementi *modela* omogućuju korisniku unos vrijednosti potrebnih za rad sustava te njihovo interpretiranje na temelju povratnih informacija. Primjeri interaktivnih elemenata su hiperveze, dijaloški okviri za unos podataka za simulaciju, podešavanje brzine animacija pomoću VCR kontrola i dr. Međutim, autori Narayanan i Hegarty (2002) ističu kako učinkovitost *modela* ovisi i o domeni znanja. Kod vrlo složenih sustava moguća je pojava dominacije dinamičnih prikaza u odnosu na statične zbog težine izvođenja mentalne simulacije promatranog sustava, gdje animacija uvelike olakšava taj proces. S druge strane, ako korisnik ima adekvatno predznanje koje mu omogućava izvođenje mentalne simulacije bez uvida u animaciju, statični prikazi mogu biti više učinkoviti u odnosu na dinamične. Rizici koji se javlja kod primjene vanjskih animiranih prikaza je sprječavanje individualnog razvoja mentalnih aktivnosti korisnika. Računalne vizualizacije trebale bi se koristiti radi unaprjeđenja sposobnosti mentalne simulacije, a ne kao zamjena za vanjske prikaze u procesu usvajanja znanja.

Istraživanja u domeni računalnih algoritama potvrdila su značajnost primjene drugog načela (engl. *the prior knowledge principle*) u algoritamskim animacijama, gdje se pokazalo kako nedostatak analogije iz predmetnog okruženja ima negativan učinak na proces razumijevanja algoritma (Hansen, S. R., 1999, prema Narayanan, N. H. i Hegarty, M., 2002). Istraživanja na području biologije pokazala su značajnost primjene trećeg načela (engl. *the co-reference principle*), ustanovivši kako se razumijevanje studenata unaprijedilo kada su učili iz video prikaza popraćenih komentarima, pri čemu su vizualni pokazivači (boje, različite oznake, simboli strelica i dr) usmjeravali njihovu pažnju na sadržajno relevantne dijelove video prikaza (Faraday, P. i Sutcliffe, A., 1997a, 1997b, prema Narayanan, N. H. i Hegarty, M., 2002). Nizom eksperimenata u mehaničkoj domeni (Hegarty, M., Narayanan, N. H. i Freitas, P., 2002, prema Narayanan, N. H. i Hegarty, M., 2002), pokazana je učinkovitost primjene petog načela (engl. *the mental simulation principle*), ustanovivši kako korisnici bolje uče iz animiranih prikaza mehaničkih sustava ako su prethodno poticani na proces mentalne animacije statičnih dijagrama sustava. Shodno tome, u domeni računalnih algoritama studenti su bolje učili iz računalnih animacija i tiskanih materijala ako ih se prethodno poticalo na predviđanje rada algoritma kroz proces mentalne simulacije (Byrne, M. D., Catrambone, R. i Stasko, J. T., 1999).

3 MULTIMEDIJSKA INSTRUKTIVNA PORUKA ZA PROGRAMSKI JEZIK LOGO

U ovom je poglavlju opisan razvoj *multimedijske instruktivne poruke za programski jezik Logo* (MIPL) koja čini temeljni materijal korišten u doktorskom istraživanju. Cjelokupni razvoj MIPL-a predstavlja samostalni rad autorice ovog rada, koja je u razdoblju između 2012.-2015. godine kao znanstveni novak predavala vježbe iz kolegija *Programski jezik LOGO* za studente razredne nastave, modula informatike, Učiteljskog fakulteta Sveučilišta u Zagrebu.

3.1 Struktura multimedijske instruktivne poruke za programski jezik LOGO

U razvoju MIPL-a (tablica 6) primijenjeno je osam osnovnih načela (*načelo multimedija, načelo prostorne povezanosti, načelo vremenske usklađenosti, načelo koherentnosti, načelo modaliteta, načelo zalihosnosti, načelo individualnih razlika, načelo signalizacije*) i jedno napredno načelo (*načelo animacije i interaktivnosti*) *kognitivne teorije multimedijskog usvajanja znanja* (KTMUZ), te načelo raščlanjivanja *modela kognitivnog procesa multimodalnog razumijevanja* (MKPMR), uzimajući u obzir sljedeće faktore:

- **sadržaj poruke** – osnovni pojmovi iz Logo programiranja (osnovne naredbe, liste naredbi, procedure, petlje, riječi, liste).
- **vrsta Logo podatka (numerički, znakovni, liste) u sadržaju poruke** – geometrijska ili negeometrijska izlazna vrijednost programa.
- **razina složenosti sadržaja poruke** – gradacija od jednostavnijih (osnovne naredbe, liste naredbi, procedure) ka složenijim konceptima (petlje, riječi, liste).

Pri tome, neki dijelovi poruke objedinjuju više načela, a neki manje, zavisno o navedenim faktorima. *Načelo individualnih razlika* i *načelo koherentnosti* primijenjeni su u razvoju svih slajdova MIPL-a. MIPL objedinjuje sintaktičko, semantičko i shematično znanje Logo jezika (Fay, A. L. i Mayer, R. E., 1988; Mayer, R. E., 1992b, prema Lehrer, R., Lee, M., Jeong, A., 1999). Sadržaj MIPL-a čine osnovni pojmovi iz 9 odabranih nastavnih tema programskog jezika Logo klasificiranih prema vrsti podatka izlazne vrijednosti programa (geometrijski/negeometrijski): *Osnovne naredbe programskog jezika, Ponavljanje niza naredbi (REPEAT petlja), Uporaba petlje za crtanje niza likova, Ulazne vrijednosti procedura (MAKE naredba), Uporaba više ulaznih vrijednosti, Crtanje kocke i kvadra, Višestruke kornjače, Tipovi podataka (numerički, znakovni, liste), Algoritmi koji koriste*

različite tipove podataka. Nastavne teme preuzete su iz Nastavnog plana i programa za osnovnu školu (MZOŠ, 2006), za peti i šesti razred osnovne škole te iz udžbenika *Terrapin Logo* (Kniewald, I., 2005).

Tablica 6. Devet načela KTMUZ-a i načelo raščlanjivanja MKPMR-a korišteni u razvoju MIPL-a

| Načelo | Opis |
|---|---|
| Načelo multimedija (engl. <i>Multimedia Principle</i>) | Načelo multimedija pretpostavlja da primatelji poruke bolje usvajaju sadržaj prezentiran riječima i slikom nego sadržaj prezentiran samo riječima. |
| Načelo prostorne povezanosti (engl. <i>Split-Attention Principle</i>) | Načelo prostorne povezanosti pretpostavlja da primatelji poruke bolje usvajaju sadržaj kod kojeg su riječi i slike prostorno integrirani nego prostorno razdvojeni. |
| Načelo vremenske usklađenosti (engl. <i>Temporal Contiguity Principle</i>) | Načelo vremenske usklađenosti pretpostavlja da primatelji poruke bolje usvajaju sadržaj sa simultanim prikazom riječi i slika nego sadržaj sa slijednom prikazom. |
| Načelo koherentnosti (engl. <i>Coherence Principle</i>) | Načelo koherentnosti pretpostavlja da primatelji poruke bolje usvajaju sadržaj kada su sadržajno nerelevantni elementi izostavljeni iz multimedijske poruke. |
| Načelo modaliteta (engl. <i>Modality Principle</i>) | Načelo modaliteta pretpostavlja da primatelji poruke bolje usvajaju sadržaj prezentiran animacijom i govorenim tekstom (naracija), nego sadržaj prezentiran animacijom i pisanim tekstom (tekst na računalnom zaslonu). |
| Načelo zalihosnosti (engl. <i>Redundancy Principle</i>) | Načelo zalihosnosti pretpostavlja da primatelji poruke bolje usvajaju sadržaj prezentiran animacijom i govorenim tekstom (naracija), nego sadržaj prezentiran animacijom, govorenim tekstom i pisanim tekstom (tekst na računalnom zaslonu). |
| Načelo individualnih razlika (engl. <i>Individual Differences Principle</i>) | Primjena načela oblikovanja multimedijske instruktivne poruke ima veći utjecaj na primatelje poruke s lošim predznanjem nego na primatelje s dobrim predznanjem. Primjena načela oblikovanja multimedijske instruktivne poruke ima veći utjecaj na primatelje poruke s boljim prostornim sposobnostima nego na primatelje sa slabijim prostornim sposobnostima. |
| Načelo signalizacije (engl. <i>Signaling Principle</i>) | Načelo signalizacije pretpostavlja da primatelji poruke bolje usvajaju sadržaj kada prikaz sadrži dodatne signale (engl. <i>signals</i>) ili znakove (engl. <i>cues</i>) kojima se ističe organizacijska struktura i sadržaj esencijalnog dijela poruke. |

| | |
|--|--|
| <p>Načelo animacije i interaktivnosti (engl. <i>Animation and Interactivity Principle</i>) (vidi poglavlje 2.2.7.9).</p> | <p>U okviru ove doktorske disertacije pojam „dinamični vizualni prikaz“ odnosi se isključivo na instrukcijsku računalnu animaciju s promjenama položaja ili translacije (engl. <i>translations</i>) objekta (grafičkog pokazivača u liku kornjače), a načelo interaktivnosti podrazumijeva kontrolu nad brzinom animacije upotrebom interaktivne grafičke ikone u formi gumba (engl. <i>button</i>): „Pokreni/Zaustavi“.</p> |
| <p>Načelo raščlanjivanja (engl. <i>The Decomposition Principle</i>) MKPMR modela računalnog algoritma na jednostavnije funkcionalne komponente ili elementarne operacije (vidi poglavlje 2.3). Proces raščlanjivanja je proces razumijevanja elementarnih operacija računalnog algoritma, što ovisi o predznanju korisnika o komponentama algoritma i vizualnim svojstvima multimedijskog prikaza. U ovoj doktorskoj disertaciji načelo raščlanjivanja prilagođeno je vrsti sadržaja poruke, odnosno proceduralnoj paradigmi programskog jezika Logo te realizirano upotrebom osnovnog načela signalizacije i naprednog načela animacije i interaktivnosti.</p> | |

Razvoj MIPL-a sastoji se od pet faza (tablica 7): (1) *podjela* nastavnih tema na tri glavne cjeline; (2) *izgradnja* multimedijских sastavnica nastavnog sadržaja; (3) *oblikovanje kontrolne* multimedijске instrukтивne poruke za programski jezik Logo (**MIPL_K**) i (4) *oblikovanje eksperimentalne* multimedijске instrukтивne poruke za programski jezik Logo (**MIPL_E**), pomoću autorskog alata *Adobe Captivate*; (5) *objavljivanje* (engl. *publishing*) **MIPL_K** i **MIPL_E** HTML verzija.

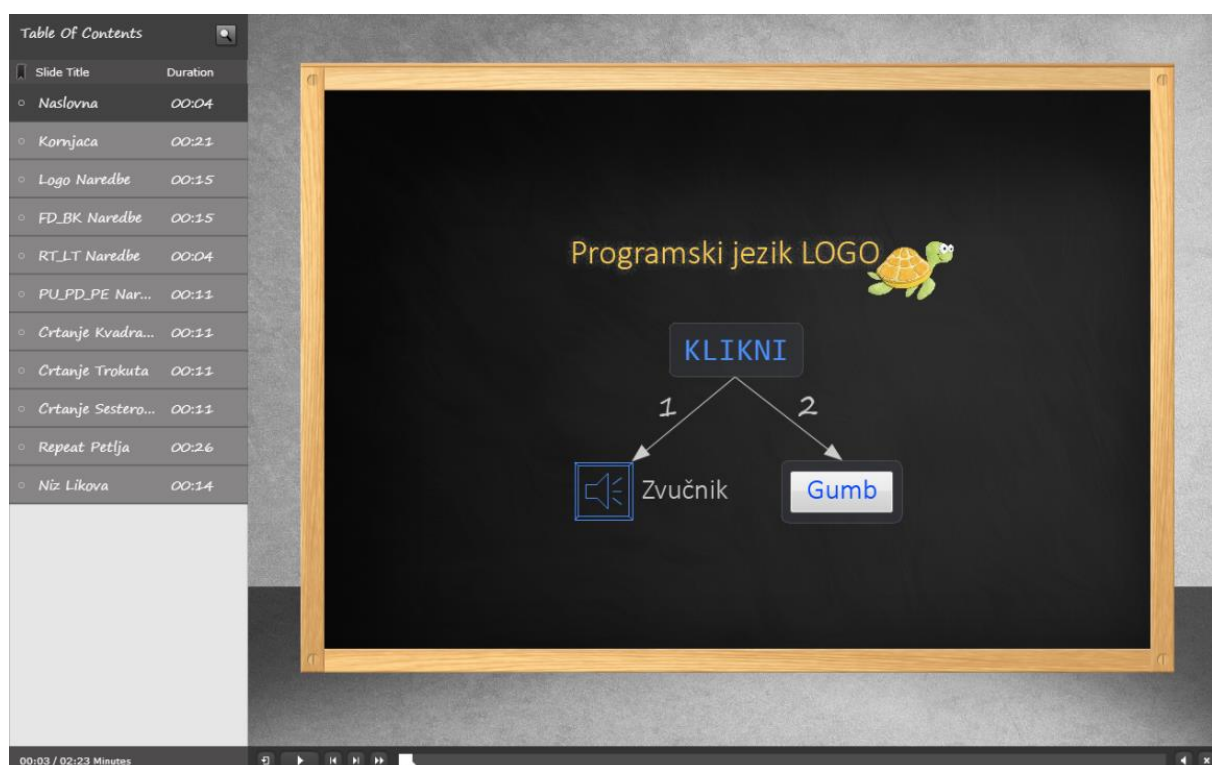
Tablica 7. Opis faza razvoja MIPL-a

| Opis |
|--|
| Prva faza |
| Podjela MIPL-a u tri glavne cjeline (globalna struktura sadržaja) |
| <ol style="list-style-type: none"> 1. Prva cjelina (geometrijska izlazna vrijednost programa): <i>osnovne naredbe programskog jezika; ponavljanje niza naredbi (REPEAT petlja); uporaba petlje za crtanje niza likova.</i> 2. Druga cjelina (geometrijska izlazna vrijednost programa): <i>ulazne vrijednosti procedura; uporaba više ulaznih vrijednosti; crtanje kocke i kvadra; višestruke kornjače.</i> 3. Treća cjelina (negeometrijska izlazna vrijednost programa): <i>tipovi podataka (numerički, znakovni, liste); MAKE naredba; WHILE petlja; FOR petlja; algoritmi koji koriste različite tipove podataka.</i> |
| Druga faza |
| Razvoj multimedijских sastavnica nastavnog sadržaja (statične i/ili pokretne slike, pisani i/ili govoreni tekst) |
| <ol style="list-style-type: none"> 1. Grafički dizajn i obrada slika (organiziranje i komuniciranje vizualnih informacija) napravljeni su pomoću programa <i>Adobe Captivate</i>, osim slika kornjače, zaslona osobnog računala i gumice za brisanje iz prve cjeline, te slike dječaka i računala iz druge cjeline, koje su preuzete s Interneta. |

| | |
|---|--|
| <ul style="list-style-type: none"> ▪ Statične slike – grafički pokazivač „kornjače“, geometrijski likovi trokuta, kvadrata, šesterokuta, niza likova te primjena znakova u sklopu vizualne signalizacije. ▪ Pokretne slike – animirani grafički pokazivač „kornjače“, iscrtavanje geometrijskih likova trokuta, kvadrata, šesterokuta, niza likova, te primjena znakova u sklopu vizualne signalizacije. ▪ Pisani tekst – definicije osnovnih naredbi, definicije programskih struktura, programski kôd te primjena znakova u sklopu vizualne signalizacije. <p>2. Snimanje, obrada i produkcija zvučnih datoteka napravljena je uz pomoć programskog paketa <i>Audacity</i> za obradu i analizu zvuka.</p> <ul style="list-style-type: none"> ▪ Govoreni tekst (naracija) – definicije i objašnjenja osnovnih naredbi, programskih struktura i programskog kôda. | |
| Treća faza | |
| <p>Oblikovanje kontrolne multimedijske instruktivne poruke za programski jezik Logo (MIPL_K) za tri nastavne cjeline (MIPL_{K1}, MIPL_{K2}, MIPL_{K3}) temelji se na KTMUZ načelima koja definiraju način organizacije i prikaz multimedijskih sastavnica nastavnog sadržaja.</p> <p>Multimedijski i instrukcijski dizajn poruke napravljen je pomoću autorskog alata <i>Adobe Captivate</i> uz primjenu 8 osnovnih KTMUZ načela: <i>načelo multimedija</i>, <i>načelo prostorne povezanosti</i>, <i>načelo vremenske usklađenosti</i>, <i>načelo koherentnosti</i>, <i>načelo modaliteta</i>, <i>načelo zalihosnosti</i>, <i>načelo individualnih razlika</i>, <i>načelo signalizacije</i>.</p> | |
| Četvrta faza | |
| <p>Oblikovanje eksperimentalne multimedijske instruktivne poruke za programski jezik Logo (MIPL_E) za tri nastavne cjeline (MIPL_{E1}, MIPL_{E2}, MIPL_{E3}) predstavlja višestruki simultani i sinergijski proces primjene KTMUZ načela i načela raščlanjivanja MKMPR-a na trenutnu kontrolnu MIPL, s ciljem kreiranja optimalne i učinkovite multimedijske poruke radi poboljšanja procesa zapamćivanja i razumijevanja sadržaja.</p> <p>Multimedijski i instrukcijski dizajn poruke napravljen je pomoću autorskog alata <i>Adobe Captivate</i> uz primjenu 8 osnovnih KTMUZ načela, naprednog načela animacije i interaktivnosti te MKPMR načela raščlanjivanja.</p> | |
| MIPL_E | |
| MIPL_{E1} = KTMUZ načela (načelo raščlanjivanja (MIPL_{K1})) | |
| Broj scena (slajdova) | 11 |
| Sveukupno trajanje | 4:44 minute |
| Naslovi | <i>Naslovna, Kornjača, Logo naredbe, FD_BK naredbe, RT_LT Naredbe, PU_PD_PE Naredbe, Crtanje Kvadrata, Crtanje Trokuta, Crtanje Šesterokuta, Repeat Petlja, Niz Likova</i> |
| MIPL_{E2} = KTMUZ načela (načelo raščlanjivanja (MIPL_{K2})) | |
| Broj scena (slajdova) | 6 |
| Sveukupno trajanje | 4:20 minuta |
| Naslovi | <i>Naslovna, Procedura, Jedna ulazna vrijednost, Dvije ulazne vrijednosti, Više ulaznih vrijednosti, Višestruke kornjače</i> |

| | |
|---|---|
| MIPL_{E3} = KTMUZ načela (načelo raščlanjivanja (MIPL_{K3})) | |
| Broj scena (slajdova) | 8 |
| Sveukupno trajanje | 00:57 minuta |
| Naslovi | <i>Naslovna, Tipovi podataka, Riječi & Liste 01, Riječi & Liste 02, Make naredba, WHILE petlja, FOR petlja, Algoritmi</i> |
| Peta faza | |

Konačne verzije MIPL_K i MIPL_E objavljene su (engl. *publish*) pomoću programa *Adobe Captivate* kao HTML verzije (slika 9) i pohranjene na optički medij (CD). Radna pozadina multimedijskog okruženja odabrana je prema ponuđenim temama programa *Adobe Captivate*.



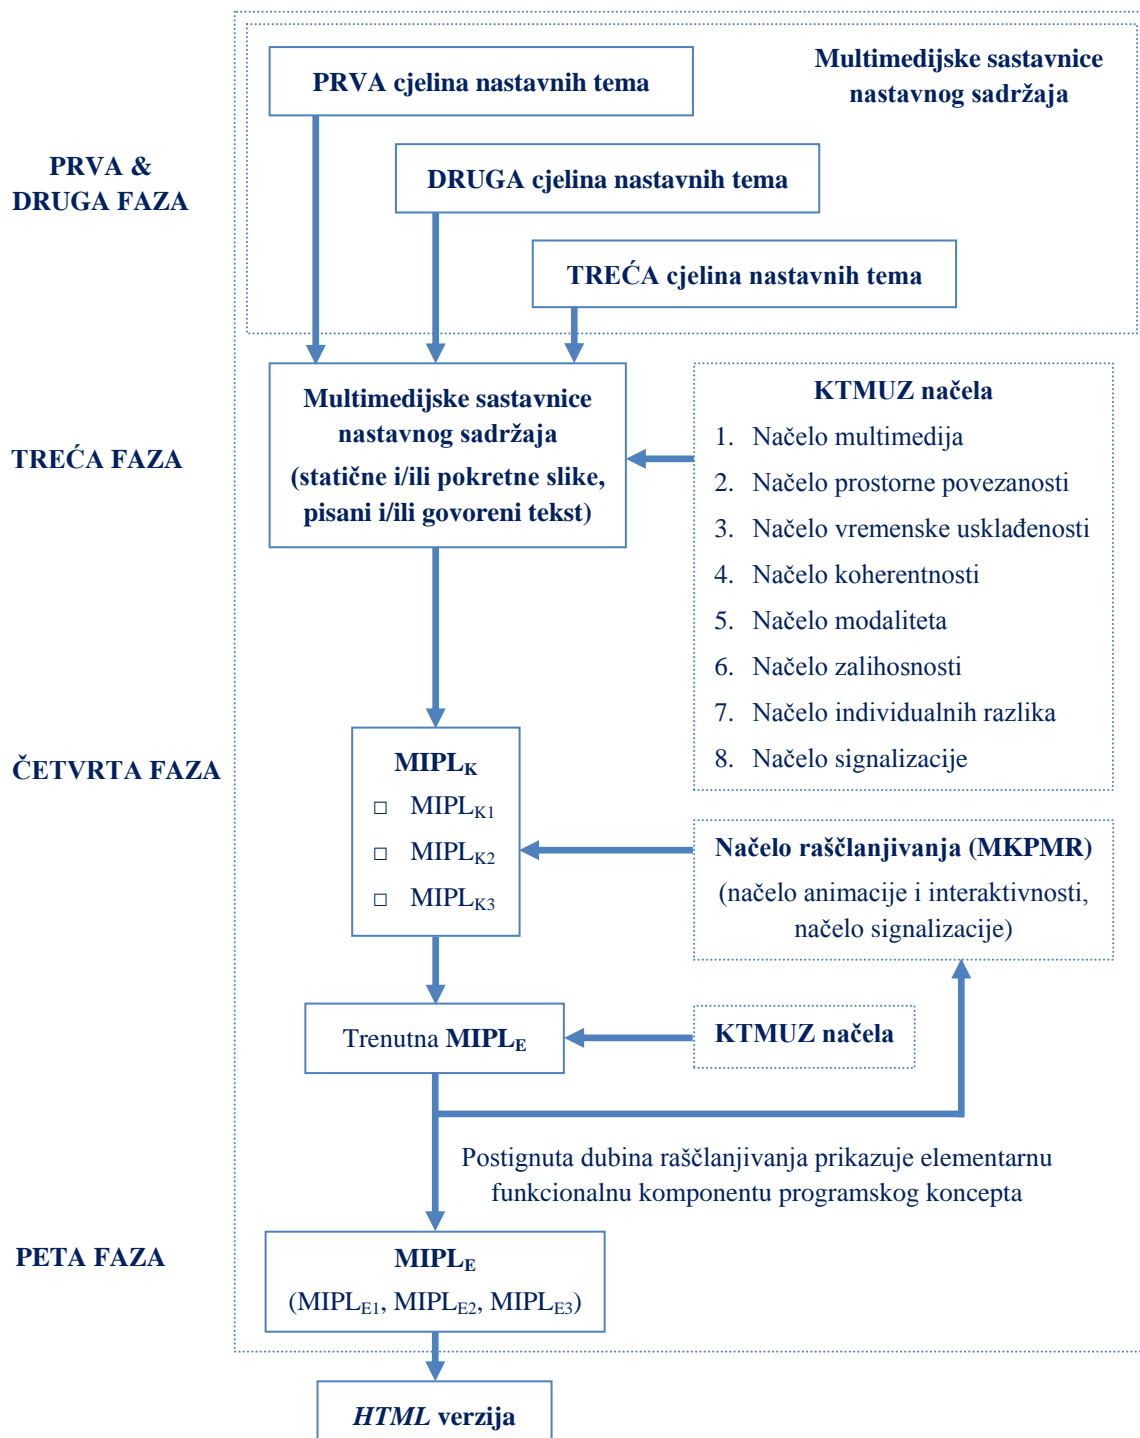
Slika 9. Uvodni slajd „Naslovna“ MIPL-a za prvu cjelinu (kontrolna i eksperimentalna skupina)

Lijeva strana MIPL radnog okruženja sadrži izbornik s naslovima slajdova i vremenom trajanja svakog slajda iz odabranih nastavnih tema. U podnožju okruženja nalazi se *vremenska linija* (engl. *timeline*) s prikazom tijeka izvođenja MIPL-a i mogućnošću vlastite navigacije korisnika kroz okruženje.

Uvodni slajd za prve dvije cjeline (MIPL_K i MIPL_E) sadrži upute u formi govorenog teksta: „Prezentirani sadržaj iz programskog jezika Logo sadrži interaktivne elemente za lakše praćenje materijala. Simbol zvučnika za govorna objašnjenja i simbol gumba za aktivaciju sadržaja“.

Uvodni slajd za treću cjelinu (MIPL_K i MIPL_E) sadrži upute u formi govorenog teksta: „Prezentirani sadržaj iz programskog jezika Logo sadrži interaktivne elemente za lakše praćenje materijala. Simbol zvučnika za govorna objašnjenja, simbol gumba za aktivaciju sadržaja i simbol za isticanje sadržaja“.

Pokretanje HTML verzija MIPLK i MIPLE ostvareno je web-preglednikom *Google Chrome*.



Slika 10. Razvoj MIPL-a

3.2 MIPL prve nastavne cjeline



Slika 11. Prvi slajd „Kornjača“ (slika lijevo) i drugi slajd „Logo Naredbe“ (slika desno) MIPL-a za prvu cjelinu (kontrolna i eksperimentalna skupina)

Tablica 8. Analiza načela MIPL-a za prvi i drugi slajd prve nastavne cjeline (kontrolna i eksperimentalna skupina)

Načelo multimedija, načelo vremenske usklađenosti, načelo zalihosnosti (prilagođeni prirodi sadržaja poruke) – multimedijски prikazi sadrže pisani tekst, sliku i govoreni tekst: (slika 11, lijevo) vizualizacija kretanja (animacija) grafičkog pokazivača „kornjače“ vremenski usklađena s govorenim tekstom ili naracijom: „U programskom jeziku LOGO programer koristi grafički pokazivač kornjače na ekranu kako bi riješio specifične zadatke povezane s kretanjem u ravlini“; (slika 11, desno) govoreni tekst (naracija) sadrži objašnjenja izraza „ključna riječ“: „Ključna riječ definira vrstu naredbe“ i „parametar“: „Parametar definira ulaznu vrijednost naredbe“, te nije vremenski usklađen s pisanim tekstom (izbor korisnika aktiviranjem interaktivnih elemenata (simbol zvučnika)).

Načelo signalizacije – (slika 11, desno) vizualno označavanje pisanog teksta (ključna riječ i parametar Logo naredbe) tipografskim signalima: plava i zelena boja fonta.

Načelo animacije i interaktivnosti – (slika 11, lijevo) animacija kretanja grafičkog pokazivača „kornjače“; (slika 11, desno) interaktivni elementi (simbol zvučnika) za aktivaciju verbalnih objašnjenja ključne riječi i parametra naredbe, te aktivaciju slajdova „FD_BK Naredbe“, „RT_LT Naredbe“, „PU_PD_PE_Naredbe“.

Konceptualni model

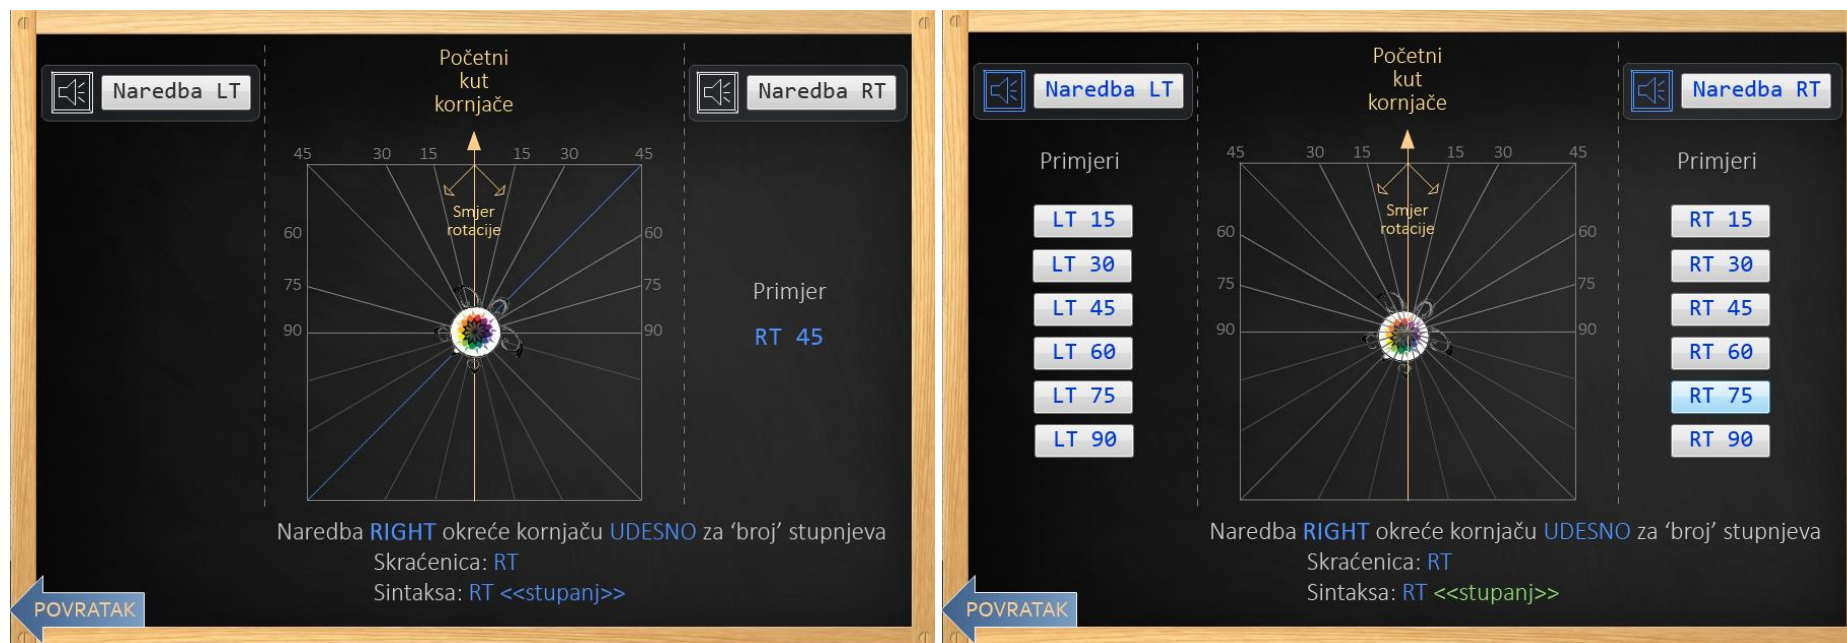
Objašnjenje programskog koncepta Logo naredbe koja se sastoji od dva dijela: ključna riječ i parametar



Slika 12. Treći slajd „FD_BK Naredbe“ MIPL-a za prvu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno)

Tablica 9. Analiza načela MIPL-a za treći slajd prve nastavne cjeline

| Kontrolna skupina – KTMUZ načela | | Eksperimentalna skupina – načelo RAŠČLANJIVANJA |
|--|--|---|
| Načelo multimedija – pisani tekst (definicije) i odgovarajuća statična vizualizacija izvođenja FD (engl. <i>forward</i>) i BK (engl. <i>back</i>) naredbi za zadane primjere (FD 10, BK 10). | | Načelo animacije i interaktivnosti – primjeri izvođenja FD i BK naredbi prikazani kao interaktivni elementi čija aktivacija pokreće animaciju linearnog kretanja kornjače prema naprijed i natrag za zadani parametar (10). Načelo signalizacije – vizualno označavanje interaktivnih elemenata za prikaz definicija naredbi (pisani tekst) i izvođenja naredbi tipografskim signalima: plava boja fonta za sve elemente prikaza koji se odnose na ključne riječi naredbe (FD, BK i dr.) i zelena boja fonta za sve elemente prikaza koji se odnose na parametre naredbi (10, <<broj>> i dr.). Vizualno označavanje zapisa parametra (<<broj>>) sintakse naredbe upotrebom strelice zelene boje. |
| Načelo prostorne povezanosti – parametri naredbi FD i BK (10) prikazani su uz odgovarajući položaj kornjače u koordinatnom sustavu. | | |
| Načelo vremenske usklađenosti i načelo zalihosnosti (prilagođeni prirodi sadržaja poruke) – multimedijски prikaz sadrži sliku, pisani tekst i govoreni tekst, gdje slika i pisani tekst nisu simultani s govorenim tekstom (izbor korisnika). Govoreni tekst (naracija) sadrži objašnjenja FD („ <i>Naredba FORWARD pomiče kornjaču naprijed za zadani broj</i> “) i BK („ <i>Naredba BACK pomiče kornjaču NATRAG za zadani broj</i> “) naredbi i aktivira se pomoću interaktivnih elemenata (simbol zvučnika). | | |
| Načelo signalizacije – vizualno označavanje: (1) pisanog teksta (definicije FD i BK naredbi) tipografskim signalom: plava boja fonta; (2) položaja kornjače upotrebom strelice plave boje za izvođenje naredbi prema zadanom parametru (10). | | |
| Načelo interaktivnosti – interaktivni elementi (simbol zvučnika) za aktivaciju verbalnih objašnjenja FD i BK naredbi. | | |
| Konceptualni model | Objašnjenje programskih koncepata – FD i BK Logo naredbi | |

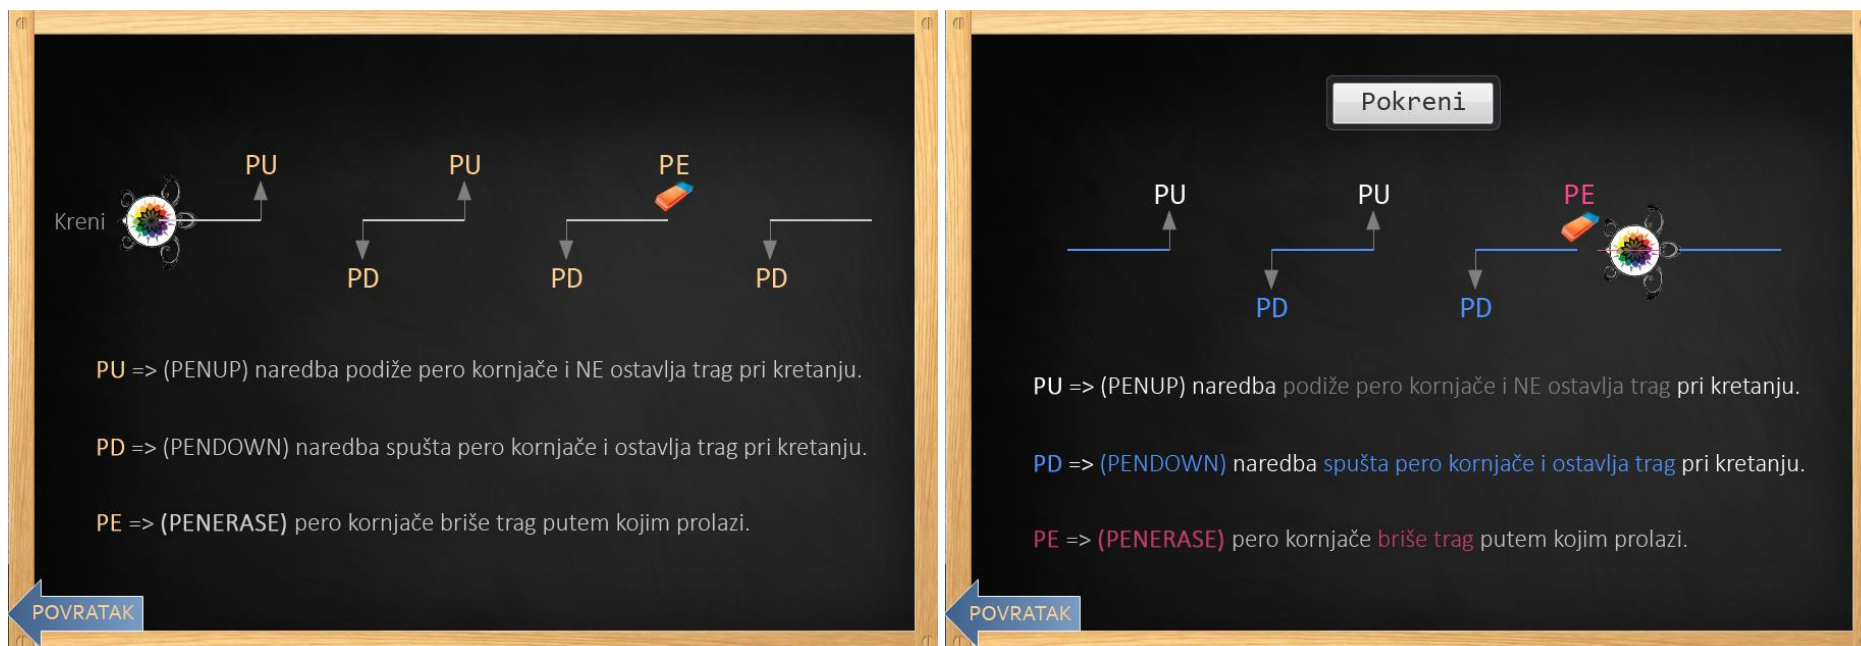


Slika 13. Četvrti slajd „RT_LT Naredbe“ MIPL-a za prvu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno)

Tablica 10. Analiza načela MIPL-a za četvrti slajd prve nastavne cjeline

| Kontrolna skupina – KMTUZ načela | Eksperimentalna skupina – načelo RAŠČLANJIVANJA |
|---|--|
| Načelo multimedija – pisani tekst (definicije) i odgovarajuća statična vizualizacija izvođenja LT (engl. <i>left</i>) i RT (engl. <i>right</i>) naredbi za zadane primjere (LT 60, RT 45). | Načelo animacije i interaktivnosti – primjeri izvođenja LT i RT naredbi prikazani kao interaktivni elementi čija aktivacija pokreće animaciju rotacije kornjače oko početnog položaja za zadane parametre (15, 30, 45, 60, 75, 90). Govoreni tekst (naracija) sadrži objašnjenja LT 15 i RT 15 naredbi glasovnim isticanjem izraza: |
| Načelo prostorne povezanosti – parametri naredbi LT i RT (kut 60, kut 45) prikazani su uz odgovarajući smjer kornjače u koordinatnom sustavu. | |
| Načelo vremenske usklađenosti i načelo zalihosnosti (prilagođeni prirodi sadržaja poruke) – | |

| | |
|--|--|
| <p>multimedijski prikaz sadrži sliku, pisani tekst i govoreni tekst, gdje slika i pisani tekst nisu simultani s govorenim tekstom (izbor korisnika). Govoreni tekst (naracija) sadrži objašnjenja LT („Naredba <i>LEFT</i> okreće kornjaču <i>ULJEVO</i> za 'broj' stupnjeva“) i RT („Naredba <i>RIGHT</i> okreće kornjaču <i>UDESNO</i> za 'broj' stupnjeva“) naredbi i aktivira se pomoću interaktivnih elemenata (simbol zvučnika).</p> | <p>„Rotacija ulijevo za 15 stupnjeva“ i „Rotacija udesno za 15 stupnjeva“, te nije vremenski usklađen s pisanim tekstom (izbor korisnika aktiviranjem interaktivnih elemenata: LT 15, RT 15).</p> |
| <p>Načelo signalizacije – vizualno označavanje: (1) pisanog teksta (definicije LT i RT naredbi) tipografskim signalom: plava boja fonta; (2) smjera rotacije kornjače upotrebom linije plave boje za izvođenje naredbi prema zadanim parametrima (60, 45).</p> | <p>Načelo signalizacije – vizualno označavanje: (1) interaktivnih elemenata za prikaz definicija naredbi (pisani tekst) i izvođenja naredbi tipografskim signalom: plava boja fonta; (2) parametra (<<stupanj>>) sintakse naredbi tipografskim signalom: zelena boja fonta.</p> |
| <p>Načelo interaktivnosti – interaktivni elementi (simbol zvučnika) za aktivaciju verbalnih objašnjenja RT i LT naredbi.</p> | |
| <p>Konceptualni model</p> | <p>Objašnjenje programskih koncepata – RT i LT Logo naredbi</p> |

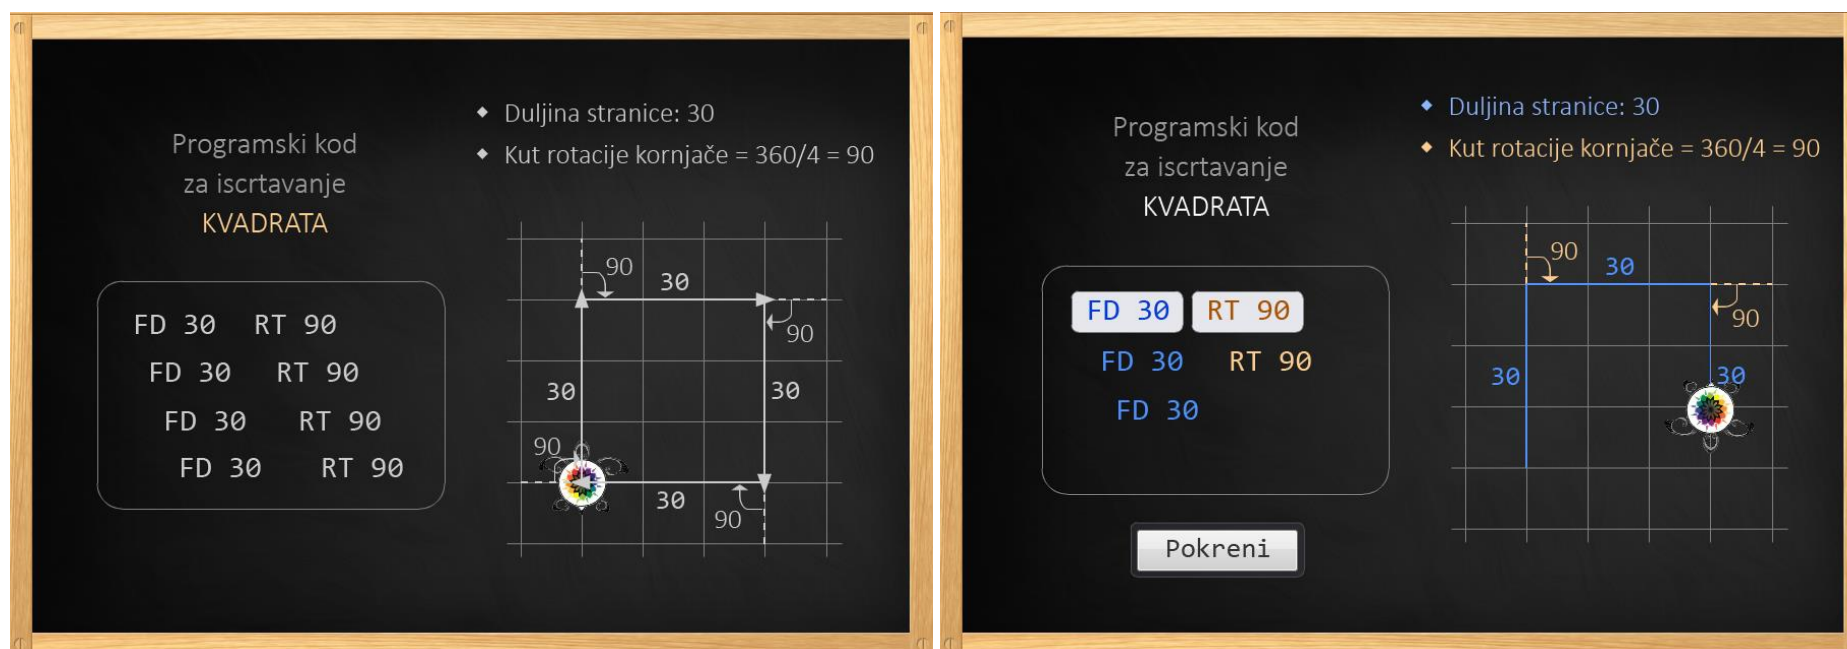


Slika 14. Peti slajd „PU_PD_PE Naredbe“ MIPL-a za prvu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno)

Tablica 11. Analiza načela MIPL-a za peti slajd prve nastavne cjeline

| Kontrolna skupina – KTMUZ načela | Eksperimentalna skupina – načelo RAŠČLANJIVANJA |
|---|--|
| <p>Načelo multimedija – pisani tekst (definicije) i odgovarajuća statična vizualizacija izvođenja PU (engl. <i>penup</i>), PD (engl. <i>pendown</i>) i PE (engl. <i>penerase</i>) naredbi.</p> | <p>Načelo animacije i interaktivnosti (uz granične uvjete načela zalihosnosti) – simultani prikaz animacije linearnog kretanja kornjače prema desno, pisanog teksta (definicija naredbe) i govorenog teksta. Govoreni tekst (naracija) nije ekvivalentna reprodukcija pisanog teksta već sadrži objašnjenja izvođenja PU, PD i PE naredbi u odgovarajućem vremenskom trenutku glasovnim isticanjem (kraćeg trajanja) izraza: „<i>podizanje pera kornjače</i>“, „<i>spuštanje pera kornjače</i>“, „<i>brisanje traga</i>“. Prikaz animacije linearnog kretanja kornjače</p> |
| <p>Načelo prostorne povezanosti – ključne riječi naredbi prikazane su na odgovarajućim mjestima statične vizualizacije.</p> | |

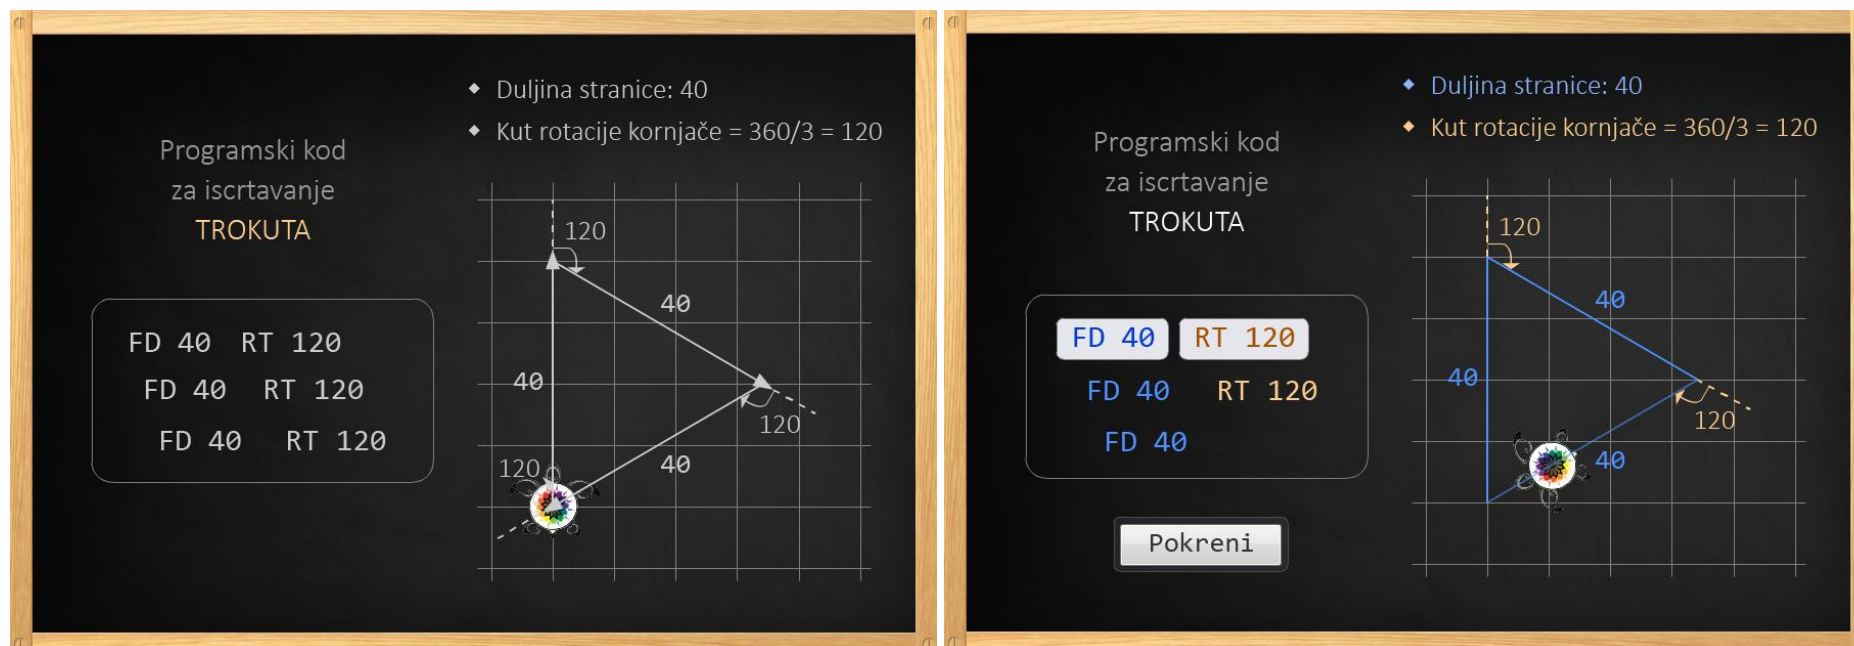
| | |
|---|--|
| <p>Načelo signalizacije – vizualno označavanje: (1) pisanog teksta (ključnih riječi PU, PD i PE) tipografskim signalom: žuta boja fonta; (2) trenutaka izvođenja PU, PD i PE naredbi upotrebom strelica sive boje; (3) trenutka izvođenja PE naredbe upotrebom slike gumice za brisanje.</p> | <p>simultano prati prikaz pisanog teksta (definicija pojedinačne naredbe), pri čemu aktivacija interaktivnog elementa „Pokreni/Zaustavi“ pokreće ili zaustavlja animaciju.</p> <p>Načelo signalizacije – vizualno označavanje: (1) pisanog teksta (ključnih riječi PU, PD i PE) tipografskim signalima: bijela, plava i ružičasta boja fonta; (2) trenutaka izvođenja PU i PD naredbi upotrebom strelica sive boje; (3) trenutka izvođenja PE naredbe upotrebom slike gumice za brisanje i linijom ružičaste boje (simbol traga kornjače) u formi „nestajanja“.</p> |
| <p>Konceptualni model</p> | <p>Objašnjenje programskih koncepata – PU, PD i PE Logo naredbi</p> |



Slika 15. Šesti slajd „Crtanje Kvadrata“ MIPL- za prvu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno)

Tablica 12. Analiza načela MIPL-a za šesti slajd prve nastavne cjeline

| Kontrolna skupina – KTMUZ načela | Eksperimentalna skupina – načelo RAŠČLANJIVANJA |
|---|---|
| <p>Načelo multimedija – pisani tekst (programski kôd) i odgovarajuća statična vizualizacija rezultata izvođenja programskog kôda za crtanje geometrijskog lika kvadrat.</p> | <p>Načelo animacije i interaktivnosti – simultani prikaz animacije linearnog kretanja i rotacije kornjače (prema zadanim parametrima naredbi – 30, 90) i pisanog teksta (lista naredbi – FD 30, RT 90, FD 30, RT 90, FD 30, RT 90, FD 30, RT 90) u formi „pojavljivanja“. Prikaz izvođenja pojedinačne naredbe simultano prati animirano kretanje kornjače, pri čemu aktivacija interaktivnog elementa „Pokreni/Zaustavi“ pokreće ili zaustavlja animaciju. Izvođenje naredbi odvija se slijedno, gdje svaka slijedeća naredba utječe na prethodnu odnosno mijenja trenutni položaj i smjer kornjače u koordinatnom sustavu. Govoreni tekst (naracija) sadrži objašnjenje izvođenja prve dvije naredbe glasovnim isticanjem izraza: „<i>Pomak kornjače za 30 piksela</i>“ i „<i>Rotacija kornjače za 90 stupnjeva</i>“, te nije vremenski usklađen s pisanim tekstom (izbor korisnika aktiviranjem interaktivnih elemenata: FD 30, RT 90).</p> |
| <p>Načelo prostorne povezanosti – parametri naredbi (duljina stranice: 30, kut rotacije: 90) postavljeni su na odgovarajuća mjesta u statičnom vizualnom prikazu geometrijskog lika kvadrat.</p> | |
| <p>Načelo signalizacije – vizualno označavanje: (1) zapisa glavne teme slajda (riječ KVADRAT) tipografskim signalom: žuta boja fonta; (2) zapisa programskog kôda (listi naredbi) upotrebom zaobljenog pravokutnika bijele boje; (3) smjera kretanja i rotacije kornjače na statičnoj slici kvadrata upotrebom strelica bijele boje.</p> | <p>Načelo signalizacije – vizualno označavanje: (1) zapisa glavne teme slajda (riječ KVADRAT) tipografskim signalom: bijela boja fonta; (2) pisanog teksta (programske naredbe FD 30 i RT 90; pisani tekst: „<i>Duljina stranice: 30</i>“ i „<i>Kut rotacije kornjače = $360/4 = 90$</i>“) tipografskim signalima: plava i svijetlo smeđa boja fonta; (3) trenutaka izvođenja naredbi prikazanim linijama plave boje (stranice kvadrata) u formi „pojavljivanja“; (4) smjera rotacije kornjače upotrebom strelice svjetlo smeđe boje.</p> |
| <p>Konceptualni model</p> | <p>Objašnjenje programskog kôda za crtanje geometrijskog lika kvadrat.</p> <p>Potrebno predznanje: poznavanje karakteristika geometrijskog lika kvadrat i osnovnih Logo naredbi za pomicanje i rotaciju kornjače (FD, RT).</p> |

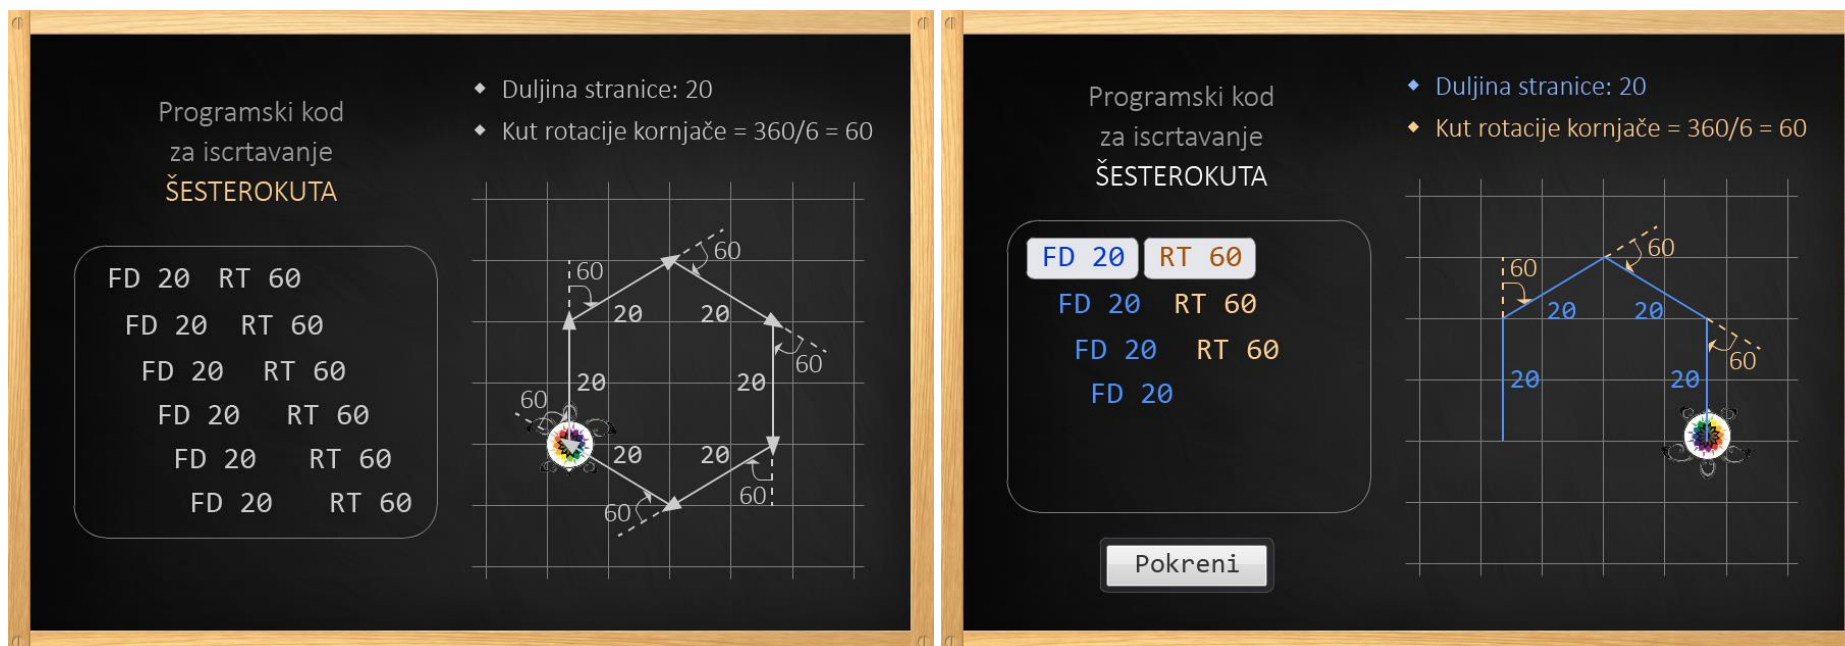


Slika 16. Sedmi slajd „Crtanje Trokuta“ MIPL-a za prvu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno)

Tablica 13. Analiza načela MIPL-a za sedmi slajd prve nastavne cjeline

| Kontrolna skupina – KTMUZ načela | Eksperimentalna skupina – načelo RAŠČLANJIVANJA |
|---|--|
| <p>Načelo multimedija – pisani tekst (programski kôd) i odgovarajuća statična vizualizacija rezultata izvođenja programskog kôda za crtanje geometrijskog lika trokut.</p> | <p>Načelo animacije i interaktivnosti – simultani prikaz animacije linearnog kretanja i rotacije kornjače (prema zadanim parametrima naredbi – 40, 120) i pisanog teksta (lista naredbi) u formi „pojavljivanja“. Prikaz izvođenja pojedinačne naredbe simultano prati animirano kretanje kornjače, pri čemu aktivacija interaktivnog elementa „Pokreni/Zaustavi“ pokreće ili zaustavlja animaciju. Izvođenje naredbi odvija se slijedno (svaka slijedeća naredba utječe na prethodnu). Govoreni tekst (naracija) sadrži objašnjenje izvođenja prve dvije naredbe</p> |
| <p>Načelo prostorne povezanosti – parametri naredbi (duljina stranice: 40, kut rotacije: 120) postavljeni su na</p> | |

| | |
|---|--|
| odgovarajuća mjesta u statičnom vizualnom prikazu geometrijskog lika trokut. | glasovnim isticanjem izraza: „ <i>Pomak kornjače za 40 piksela</i> “ i „ <i>Rotacija kornjače za 120 stupnjeva</i> “, te nije vremenski usklađen s pisanim tekstom (izbor korisnika aktiviranjem interaktivnih elemenata: FD 40, RT 120). |
| <p>Načelo signalizacije – vizualno označavanje: (1) zapisa glavne teme slajda (riječ TROKUT) tipografskim signalom: žuta boja fonta; (2) zapisa programskog kôda (listi naredbi) upotrebom zaobljenog pravokutnika bijele boje; (3) smjera kretanja i rotacije kornjače na statičnoj slici trokuta upotrebom strelica bijele boje.</p> | <p>Načelo signalizacije – vizualno označavanje: (1) zapisa glavne teme slajda (riječ TROKUT) tipografskim signalom: bijela boja fonta; (2) pisanog teksta (programske naredbe FD 40 i RT 120; pisani tekst: „<i>Duljina stranice: 40°</i>“ i „<i>Kut rotacije kornjače = $360/3 = 120^\circ$</i>“) tipografskim signalima: plava i svijetlo smeđa boja fonta; (3) trenutaka izvođenja naredbi prikazanim linijama plave boje (stranice trokuta) u formi „pojavljivanja“; (4) smjera rotacije kornjače upotrebom strelice svjetlo smeđe boje.</p> |
| <p>Konceptualni model</p> | <p>Objašnjenje programskog kôda za crtanje geometrijskog lika trokut.</p> <p>Potrebno predznanje: poznavanje karakteristika geometrijskog lika trokut i osnovnih Logo naredbi za pomicanje i rotaciju kornjače (FD, RT).</p> |

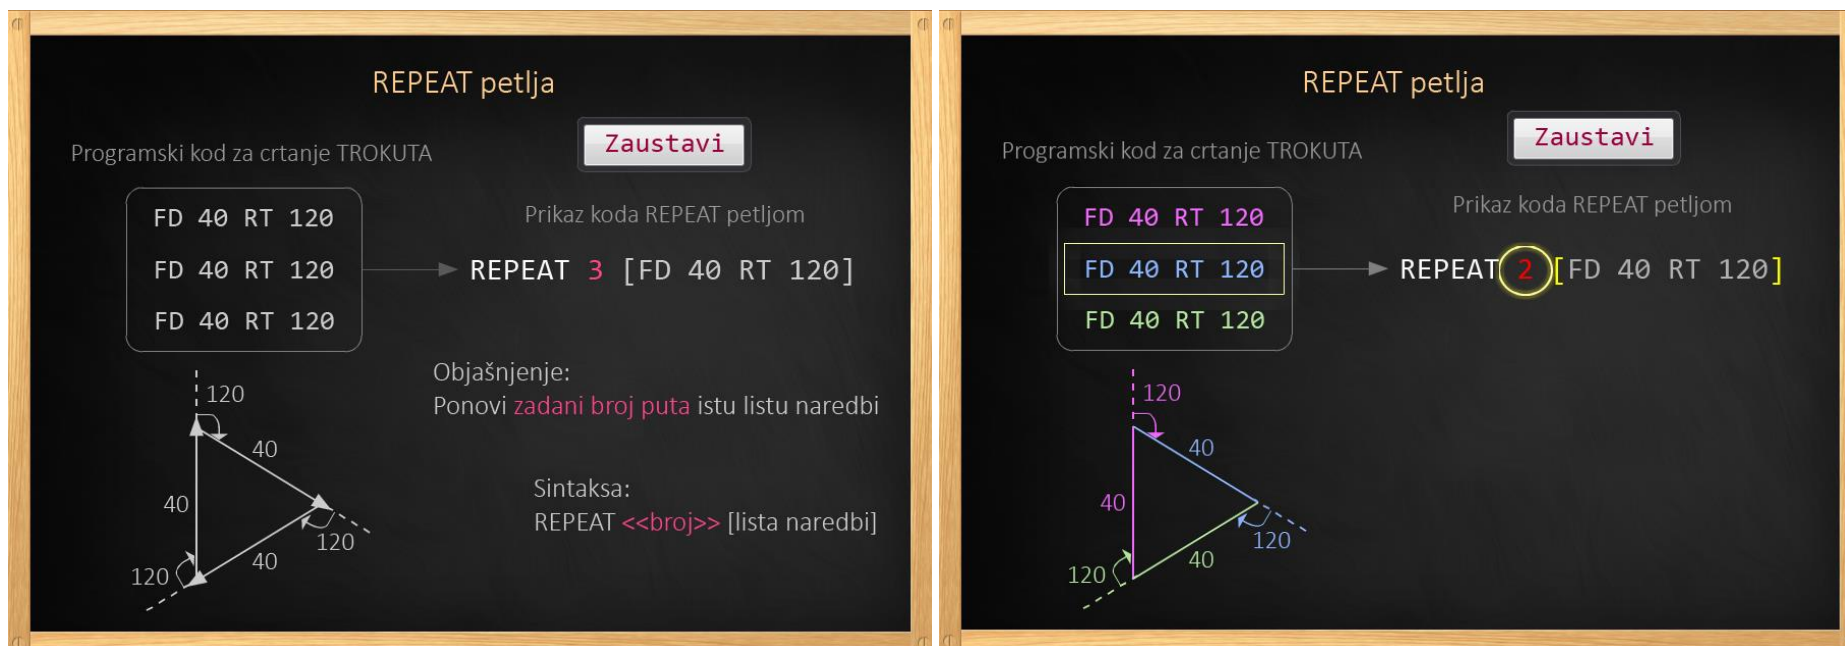


Slika 17. Osmi slajd „Crtanje Šesterokuta“ MIPL-a za prvu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno)

Tablica 14. Analiza načela MIPL-a za osmi slajd prve nastavne cjeline

| Kontrolna skupina – KTMUZ načela | Eksperimentalna skupina – načelo RAŠČLANJIVANJA |
|---|---|
| <p>Načelo multimedija – pisani tekst (programski kôd) i odgovarajuća statična vizualizacija rezultata izvođenja programskog kôda za crtanje geometrijskog lika šesterokut.</p> | <p>Načelo animacije i interaktivnosti – simultani prikaz animacije linearnog kretanja i rotacije kornjače (prema zadanim parametrima naredbi – 20, 60) i pisanog teksta (lista naredbi) u formi „pojavljivanja“. Prikaz izvođenja pojedinačne naredbe simultano prati animirano kretanje kornjače, pri čemu aktivacija interaktivnog elementa „Pokreni/Zaustavi“ pokreće ili zaustavlja animaciju. Izvođenje naredbi odvija se slijedno (svaka slijedeća naredba utječe na prethodnu).</p> |
| <p>Načelo prostorne povezanosti – parametri naredbi (duljina stranice: 20, kut rotacije: 60) postavljeni su na odgovarajuća</p> | |

| | | |
|---|--|--|
| mjestu u statičnom vizualnom prikazu geometrijskog lika šesterokut. | <p>Govoreni tekst (naracija) sadrži objašnjenje izvođenja prve dvije naredbe glasovnim isticanjem izraza: „<i>Pomak kornjače za 20 piksela</i>“ i „<i>Rotacija kornjače za 60 stupnjeva</i>“, te nije vremenski usklađen s pisanim tekstom (izbor korisnika aktiviranjem interaktivnih elemenata: FD 20, RT 60).</p> <p>Načelo signalizacije – vizualno označavanje: (1) zapisa glavne teme slajda (riječ ŠESTEROKUT) tipografskim signalom: žuta boja fonta; (2) zapisa programskog kôda (listi naredbi) upotrebom zaobljenog pravokutnika bijele boje; (2) smjera kretanja i rotacije kornjače na statičnoj slici šesterokuta upotrebom strelica bijele boje.</p> <p>Načelo signalizacije – vizualno označavanje: (1) zapisa glavne teme slajda (riječ ŠESTEROKUT) tipografskim signalom: bijela boja fonta; (2) pisanog teksta (programske naredbe FD 20 i RT 60; pisani tekst: „<i>Duljina stranice: 20</i>“ i „<i>Kut rotacije kornjače = 360/6 = 60</i>“) tipografskim signalima: plava i svijetlo smeđa boja fonta; (3) trenutaka izvođenja naredbi prikazanim linijama plave boje (stranice šesterokuta) u formi „pojavljivanja“; (4) smjera rotacije kornjače upotrebom strelice svijetlo smeđe boje.</p> | |
| Konceptualni model | <p style="text-align: center;">Objašnjenje programskog kôda za crtanje geometrijskog lika šesterokut</p> <p>Potrebno predznanje: poznavanje karakteristika geometrijskog lika šesterokut i osnovnih Logo naredbi za pomicanje i rotaciju kornjače (FD, RT).</p> | |

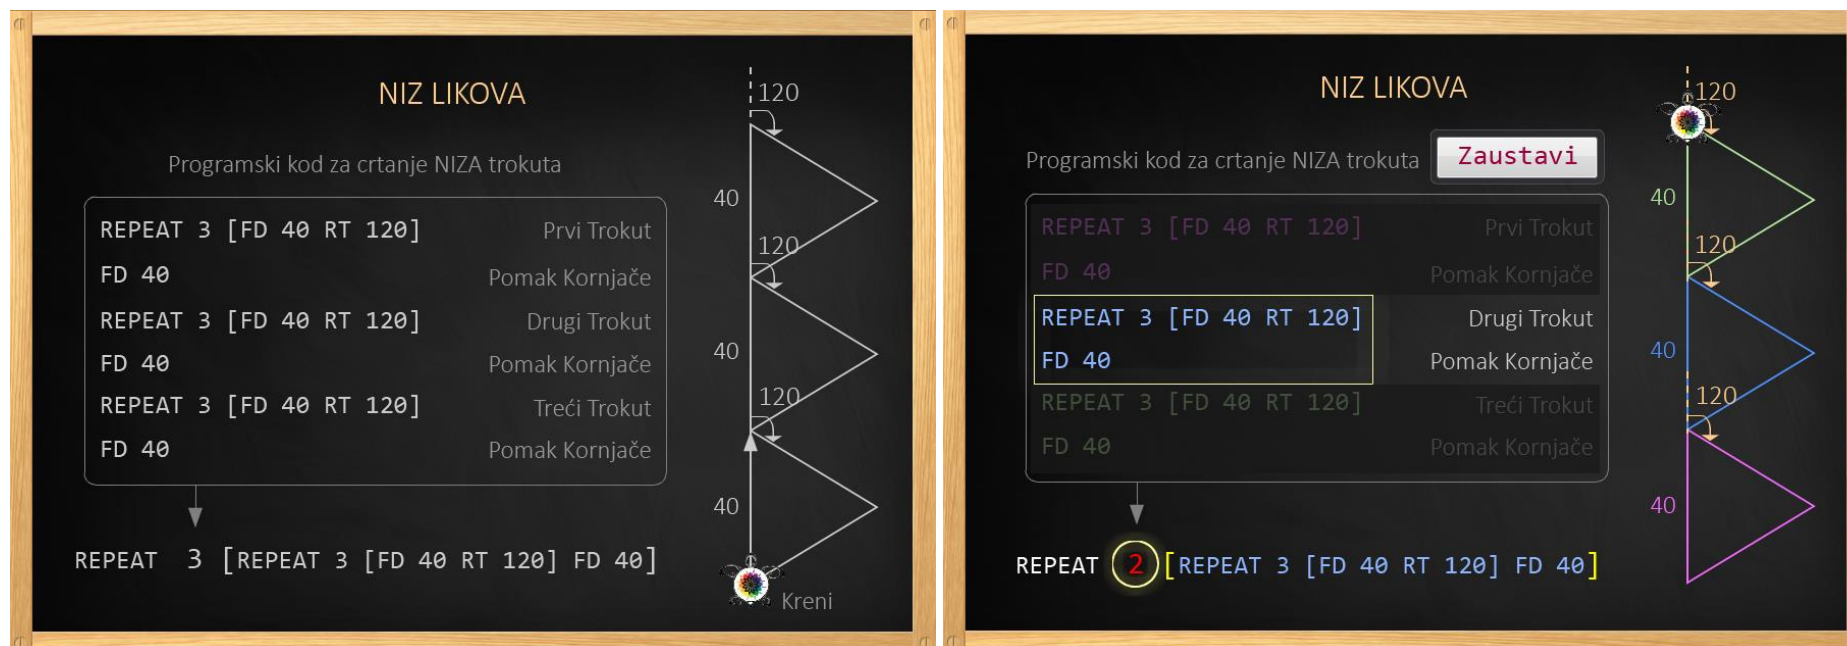


Slika 18. Deveti slajd „Repeat Petlja“ MIPL-a za prvu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno)

Tablica 15. Analiza načela MIPL-a za deveti slajd prve nastavne cjeline

| Kontrolna skupina – KTMUZ načela | Eksperimentalna skupina – načelo RAŠČLANJIVANJA |
|---|---|
| <p>Načelo multimedija, načelo vremenske usklađenosti – multimedijски prikaz sadrži pisani tekst, sliku i govoreni tekst. Pisani tekst sadrži prikaz programskog kôda u formi liste naredbi i skraćenom obliku pomoću REPEAT petlje. Slika sadrži statičnu vizualizaciju rezultata izvođenja programskog kôda za crtanje geometrijskog lika trokut. Govoreni tekst (naracija) sadrži konceptualno objašnjenje programskog kôda za crtanje trokuta („Programski kod za iscrtavanje jednakostraničnog trokuta sadrži ISTE liste naredbi koje se ponavljaju 3 puta“) i</p> | <p>Načelo signalizacije – vizualno označavanje: (1) pisanog teksta (liste naredbi FD 40, RT 120) tipografskim signalima: ružičasta, plava i zelena boja fonta u formi „pojavljivanja“; (2) prikaza stranica geometrijskog lika trokut upotrebom linija ružičaste, plave i zelene boje u formi „pojavljivanja“; (3) zapisa vrijednosti duljine stranica i kuta rotacije kornjače na statičnoj slici trokuta tipografskim signalima: ružičasta, plava i zelena boja fonta; (4)</p> |

| | | |
|--|---|---|
| najavu REPEAT petlje („ <i>ISTE liste naredbi, u skraćenom je obliku, moguće zapisati pomoću REPEAT petlje</i> “). | | smjera rotacije kornjače upotrebom strelica ružičaste, plave i zelene boje; (5) zapisa broja ponavljanja (triju) listi naredbi unutar REPEAT petlje tipografskim signalom: crvena boja fonta; (6) zapisa listi naredbi i broja ponavljanja REPEAT petlje upotrebom pravokutnika i kruga žute boje u formi „bljeskanja“; (7) tekstualnog objašnjenja REPEAT petlje tipografskim signalom: ružičasta boja fonta. Verbalno označavanje liste naredbi i odgovarajućeg broja ponavljanja unutar REPEAT petlje glasovnim isticanjem: „ <i>Prvo ponavljanje liste naredbi</i> “, „ <i>Drugo ponavljanje liste naredbi</i> “, „ <i>Treće ponavljanje liste naredbi</i> “. Sva vizualna označavanja relevantnih dijelova poruke vremenski su usklađena s verbalnim označavanjem. |
| Načelo prostorne povezanosti – parametri naredbi (duljina stranice: 40, kut rotacije: 120) postavljeni su na odgovarajuća mjesta u statičnom vizualnom prikazu geometrijskog lika trokut. | | |
| Načelo signalizacije – vizualno označavanje: (1) naslova slajda (REPEAT petlja) tipografskim signalom: žuta boja fonta; (2) zapisa programskog kôda (liste naredbi) upotrebom zaobljenog pravokutnika bijele boje; (3) smjera kretanja i rotacije kornjače na statičnoj slici trokuta upotrebom strelica bijele boje; (4) zapisa broja ponavljanja (triju) listi naredbi unutar zapisa REPET petlje i tekstualnog objašnjenja tipografskim signalom: ružičasta boja fonta. | | |
| Načelo interaktivnosti – interaktivni element „Pokreni/Zaustavi“ pokreće ili zaustavlja prikaz poruke. | | |
| Konceptualni model | Objašnjenje programske strukture REPEAT petlje Potrebno predznanje: poznavanje karakteristika geometrijskog lika trokut i osnovnih Logo naredbi za pomicanje i rotaciju kornjače (FD, RT). | |



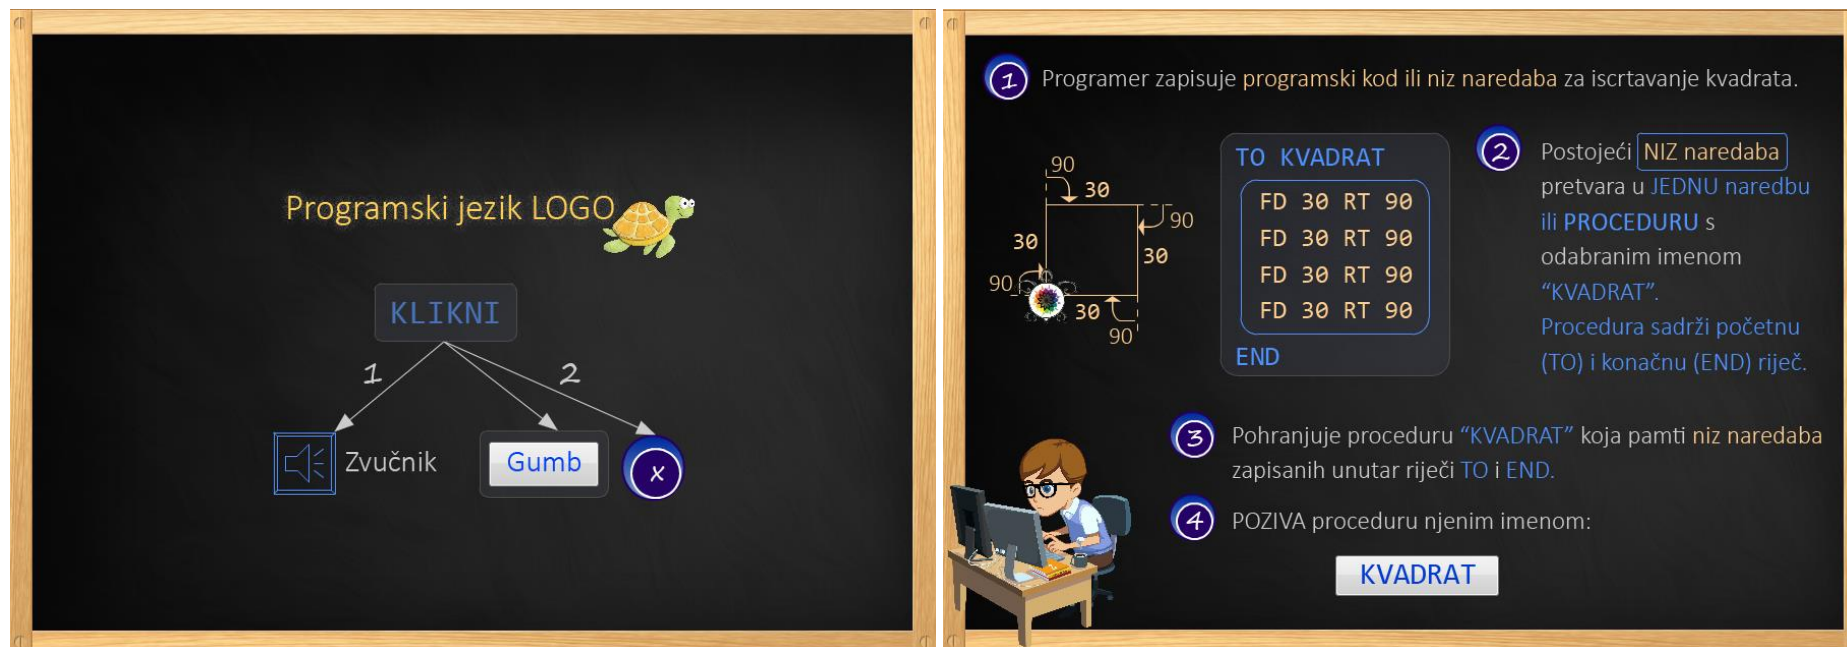
Slika 19. Deseti slajd „Niz Likova“ MIPL-a za prvu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno)

Tablica 16. Analiza načela MIPL-a za deseti slajd prve nastavne cjeline

| Kontrolna skupina – KTMUZ načela | Eksperimentalna skupina – načelo RAŠČLANJIVANJA |
|---|--|
| <p>Načelo multimedija – multimedijски prikaz sadrži pisani tekst i sliku. Pisani tekst sadrži prikaz programskog kôda za crtanje niza likova (tri trokuta) u formi liste naredbi i skraćenom obliku (REPEAT petlja). Slika sadrži statičnu</p> | <p>Načelo animacije i interaktivnosti – simultani prikaz animacije linearnog kretanja i rotacije kornjače (prema zadanim parametrima naredbi – 40, 120), pisanog teksta (liste naredbi) u formi „pojavljivanja“ i govorenog teksta. Govoreni tekst (naracija) nije ekvivalentna reprodukcija pisanog teksta već glasovno isticanje (kraćeg trajanja) izvođenja određene liste naredbi (REPEAT petlja) i pojedinačne naredbe (FD 40) u odgovarajućem vremenskom trenutku. Prikaz izvođenja programske strukture i pojedinačne naredbe simultano prati animirano kretanje kornjače, pri čemu aktivacija interaktivnog elementa „Pokreni/Zaustavi“ pokreće ili zaustavlja animaciju.</p> |

| | | |
|---|---|--|
| vizualizaciju rezultata izvođenja programskog kôda za crtanje niza likova. | <p>Načelo signalizacije – vizualno označavanje: (1) pisanog teksta (liste naredbi u formi REPEAT petlje i pojedinačne naredbe) tipografskim signalima: ružičasta, plava i zelena boja fonta u formi „pojavljivanja“; (2) prikaza stranica trokuta upotrebom linija ružičaste, plave i zelene boje; (3) zapisa vrijednosti duljine stranica i kuta rotacije kornjače na statičnim slikama tipografskim signalima: ružičasta, plava, zelena i svjetlo smeđa boja fonta; (4) smjera rotacije kornjače upotrebom strelica svjetlo smeđe boje; (5) zapisa broja ponavljanja (triju) listi naredbi unutar REPEAT petlje tipografskim signalom: crvena boja fonta; (6) zapisa listi naredbi u formi REPEAT petlje i pojedinačnih naredbi upotrebom pravokutnika i kruga žute boje u formi „bljeskanja“, te simultanim „zatomnjenjem“ preostalog dijela programskog kôda.</p> <p>Verbalno označavanje: (1) listi naredbi i odgovarajućeg broja ponavljanja unutar REPEAT petlje glasovnim isticanjem: „<i>Prvo ponavljanje liste naredbi</i>“, „<i>Drugo ponavljanje liste naredbi</i>“, „<i>Treće ponavljanje liste naredbi</i>“; (2) organizacije programskog kôda glasovnim isticanjem vremenskih trenutaka izvođenja prve REPEAT petlje („<i>Iscrtavanje prvog trokuta</i>“), prvog pomaka kornjače za 40 piksela („<i>Pomak kornjače</i>“), druge REPEAT petlje („<i>Iscrtavanje drugog trokuta</i>“), drugog pomaka kornjače za 40 piksela („<i>Pomak kornjače</i>“), treće REPEAT petlje („<i>Iscrtavanje trećeg trokuta</i>“) i trećeg pomaka kornjače za 40 piksela („<i>Pomak kornjače</i>“).</p> <p>Sva vizualna označavanja relevantnih dijelova poruke vremenski su usklađena s verbalnim označavanjem.</p> | |
| <p>Načelo prostorne povezanosti – parametri naredbi (duljina stranice: 40, kut rotacije: 120) postavljeni su na odgovarajuća mjesta u statičnom vizualnom prikazu.</p> | | |
| <p>Načelo signalizacije – vizualno označavanje: (1) zapisa naslova slajda (NIZ LIKOVA) tipografskim signalom: žuta boja fonta; (2) zapisa programskog kôda upotrebom zaobljenog pravokutnika bijele boje; (3) smjera kretanja i rotacije kornjače na statičnoj slici trokuta upotrebom strelica bijele boje.</p> | | |
| Konceptualni model | <p style="text-align: center;">Objašnjenje programskog kôda za crtanje NIZA LIKOVA</p> <p>Potrebno predznanje: poznavanje karakteristika geometrijskog lika trokut, osnovnih Logo naredbi za pomicanje i rotaciju kornjače (FD, RT) i programske strukture REPEAT petlje.</p> | |

3.3 MIPL druge nastavne cjeline



Slika 20. Uvodni slajd „Naslovna“ (slika lijevo) i prvi slajd „Procedura“ (slika desno) MIPL-a za drugu cjelinu (kontrolna i eksperimentalna skupina)

Tablica 17. Analiza načela MIPL-a za prvi slajd „Procedura“ druge nastavne cjeline (kontrolna i eksperimentalna skupina)

Načelo multimedija – multimedijски prikaz sadrži pisani tekst (programski kôd, tekstualna objašnjenja) i odgovarajuće statične vizualizacije (lik „dječaka programera“, geometrijski lik kvadrat).

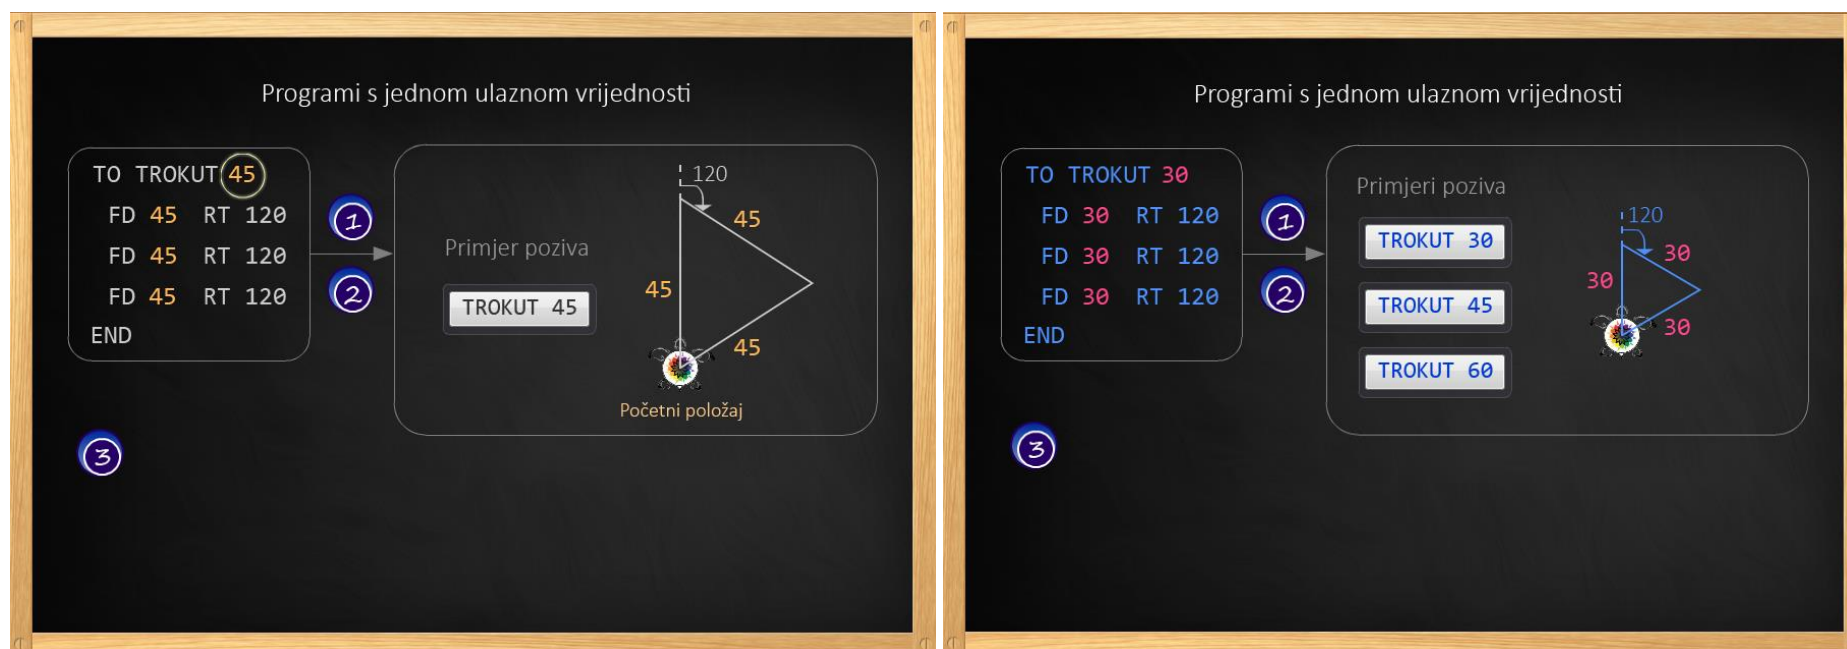
Načelo koherentnosti – nije posve ispunjeno, jer multimedijски prikaz sadrži sliku „dječaka programera“ što predstavlja sadržajno nerelevantni i zanimljivi element prikaza, ali ujedno i komunicira poruku korisniku: *programer je zadužen za stvaranje procedure*.

Načelo signalizacije – vizualno označavanje: (1) pisanog teksta u prikazu pojedinačnog koraka stvaranja procedure tipografskim signalima: svjetlosmeđa boja fonta za sve elemente prikaza koji se odnose na programski kôd (lista naredbi) i plava boja fonta za sve elemente prikaza koji se odnose na objašnjenje procedure (ključne riječi TO i END, ime procedure); (2) zapisa programskog kôda upotrebom zaobljenih pravokutnika sive i plave boje; (3) zapisa vrijednosti duljine stranice i kuta rotacije kornjače tipografskim signalima: svjetlosmeđa boja fonta; (4) smjera rotacije kornjače upotrebom strelica svjetlo smeđe boje.

Načelo interaktivnosti – interaktivni elementi za aktivaciju: (1) pisanog teksta u četiri koraka kojima se objašnjava postupak stvaranja procedure; (2) statičnog vizualnog prikaza geometrijskog lika kvadrat kao rezultat pozivanja procedure „KVADRAT“.

Konceptualni model

Objašnjenje stvaranja procedure kroz četiri koraka u programskom jeziku Logo.



Slika 21. Drugi slajd „Jedna Ulazna Vrijednost“ MIPL-a za drugu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno)

Tablica 18. Analiza načela MIPL-a za drugi slajd druge nastavne cjeline

| Kontrolna skupina – KTMUZ načela | Eksperimentalna skupina – načelo RAŠČLANJIVANJA |
|--|--|
| <p>Načelo multimedija, načelo modaliteta, načelo vremenske usklađenosti (prilagođeni prirodi sadržaja poruke) – multimedijски prikaz sadrži pisani tekst, sliku i govoreni tekst, gdje je pisani tekst vremenski usklađen s govorenim tekstom u trenutku aktivacije odgovarajućeg interaktivnog elementa. Pisani tekst sadrži prikaz procedura (programski kôd) za crtanje geometrijskog lika trokut s nepromjenjivom vrijednosti duljine stranice 30 i jednom ulaznom vrijednosti duljine stranice A (45). Slika sadrži statičnu vizualizaciju rezultata izvođenja poziva procedura „TROKUT“, „TROKUT A“ i „TROKUT 45“. Govoreni tekst (naracija) sadrži najavu: (1) procedure s jednom ulaznom vrijednosti A (<i>„Postavljanjem varijable A u programski kôd, dobiva se procedura za iscrtavanje trokuta s promjenjivom vrijednosti duljine stranice A“</i>); (2) procedure s jednom ulaznom vrijednosti 45 (<i>„Nakon poziva, procedura preuzima vrijednost 45 i postavlja je na sva mjesta varijable A u programskom kôdu“</i>); (3) upotrebe REPEAT petlje (<i>„Zapis procedura u skraćenom obliku pomoću REPEAT petlje“</i>).</p> | <p>Načelo interaktivnosti – dodatna dva interaktivna elementa za aktivaciju: (1) statičnog vizualnog prikaza geometrijskog lika trokut kao rezultat pozivanja procedura „TROKUT 30“ i „TROKUT 60“; (2) zapisa procedura „TROKUT 30“ i „TROKUT 60“.</p> <p>Načelo signalizacije – vizualno označavanje: (1) imena procedura i sadržajno relevantnih znakova i riječi (TROKUT, TO, END, FD, RT, 120) tipografskim signalom: plava boja fonta; (2) zapisa vrijednosti duljina stranica trokuta (30; 45; 60; A) unutar procedura i na statičnim vizualnim prikazima tipografskim signalom: ružičasta boja fonta; (3) zapisa i poziva procedura upotrebom zaobljenog pravokutnika bijele boje; (4) mjesta rotacije kornjače na statičnoj slici trokuta duljine stranice od 30 piksela upotrebom strelice plave boje; (5) zapisa promjenjive vrijednosti A upotrebom kruga žute boje u formi „bljeskanja“.</p> |
| <p>Načelo prostorne povezanosti – parametri naredbi (duljine stranica: 30, 45; kut rotacije: 120) postavljeni su na odgovarajuća mjesta u statičnim vizualnim prikazima geometrijskog lika trokut.</p> | |
| <p>Načelo signalizacije – vizualno označavanje: (1) imena procedure „TO TROKUT“, imena varijable „A“ i vrijednosti duljine stranice od 45 piksela tipografskim signalom: svjetlosmeđa boja fonta; (2) zapisa i poziva procedura upotrebom zaobljenog pravokutnika bijele boje; (3) mjesta rotacije kornjače na statičnoj slici trokuta duljine stranice od 45 piksela upotrebom strelice bijele boje; (4) zapisa vrijednosti duljine stranice i kuta rotacije kornjače tipografskim signalom: bijela boja fonta; (5) zapisa promjenjive vrijednosti A upotrebom kruga žute boje u formi „bljeskanja“.</p> | |
| <p>Načelo animacije i interaktivnosti – interaktivni elementi za aktivaciju: (1) pisanog teksta (procedura „TROKUT“) i statične slike (geometrijski lik trokuta) kao rezultat izvođenja programa s nepromjenjivom duljinom stranice (30); (2) statičnog vizualnog prikaza geometrijskog lika trokut s promjenjivom duljinom stranice A (45; 60) kao rezultat pozivanja procedura: „TROKUT 45“ i „TROKUT 60“; (3) zapisa procedura („TROKUT“, „TROKUT A“) u skraćenom obliku pomoću REPEAT petlje.</p> | |

| | |
|---------------------------|---|
| Konceptualni model | <p style="text-align: center;">Objašnjenje procedure s jednom ulaznom vrijednosti.</p> <p>Potrebno predznanje: poznavanje karakteristika geometrijskog lika trokut, osnovnih Logo naredbi za pomicanje i rotaciju kornjače (FD, RT) i programske strukture REPEAT petlje.</p> |
|---------------------------|---|


Programi s dvjema ulaznim vrijednostima
Procedura za crtanje PRAVOKUTNIKA

Nepromjenjive duljine stranica

TO PRAVOKUTNIK
 FD 25 RT 90
 FD 50 RT 90
 FD 25 RT 90
 FD 50 RT 90
 END

Zaustavi

Poziv procedure:
PRAVOKUTNIK



Početni položaj


Programi s dvjema ulaznim vrijednostima
Procedura za crtanje PRAVOKUTNIKA

Nepromjenjive duljine stranica

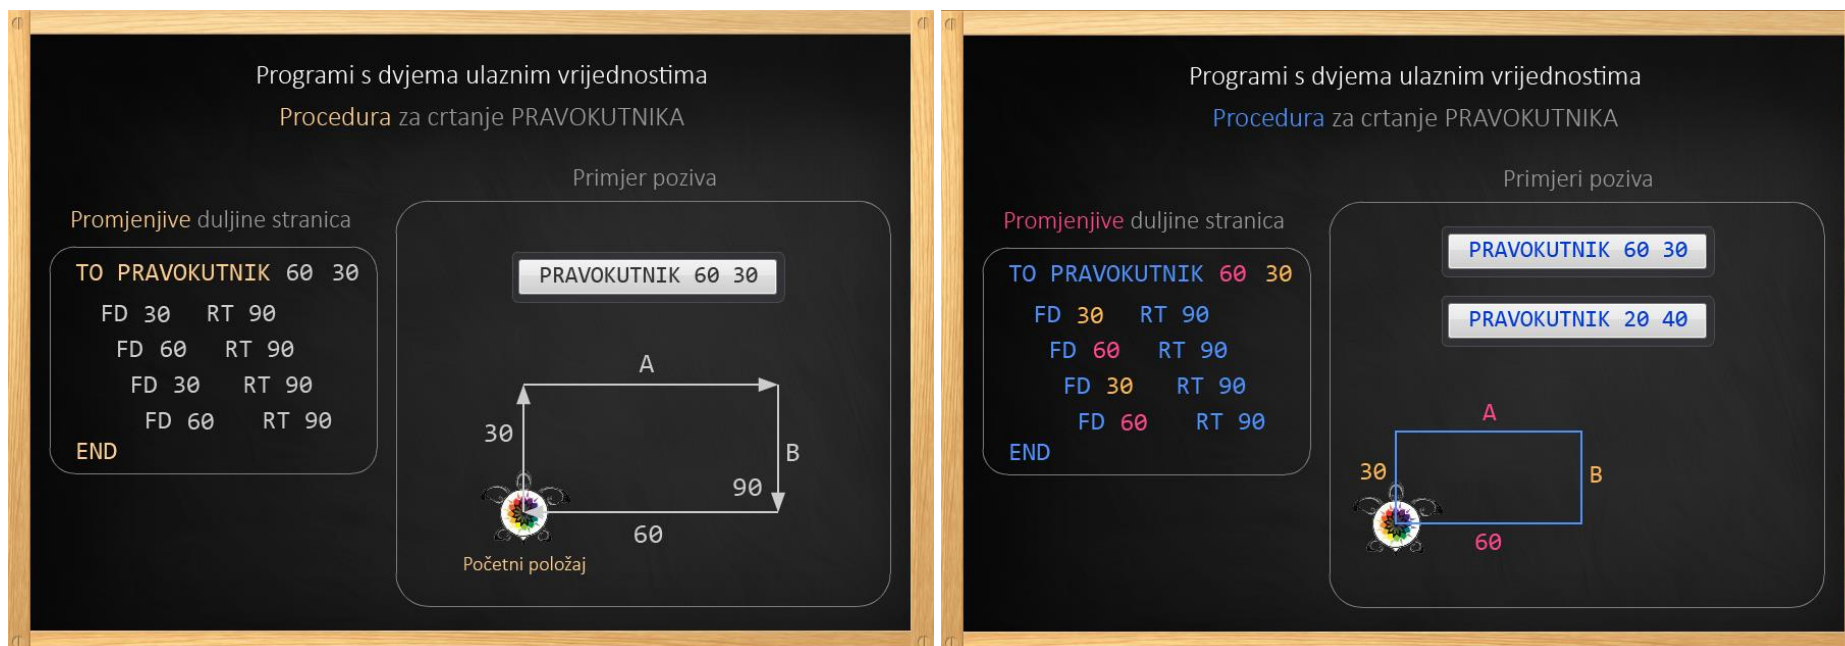
TO PRAVOKUTNIK
 FD 25 RT 90
 FD 50 RT 90
 FD 25 RT 90
 FD 50 RT 90
 END

Pokreni

Poziv procedure:
PRAVOKUTNIK



Slika 22. Treći slajd „Dvije Ulazne Vrijednosti“ (prvi dio) MIPL-a za drugu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno)

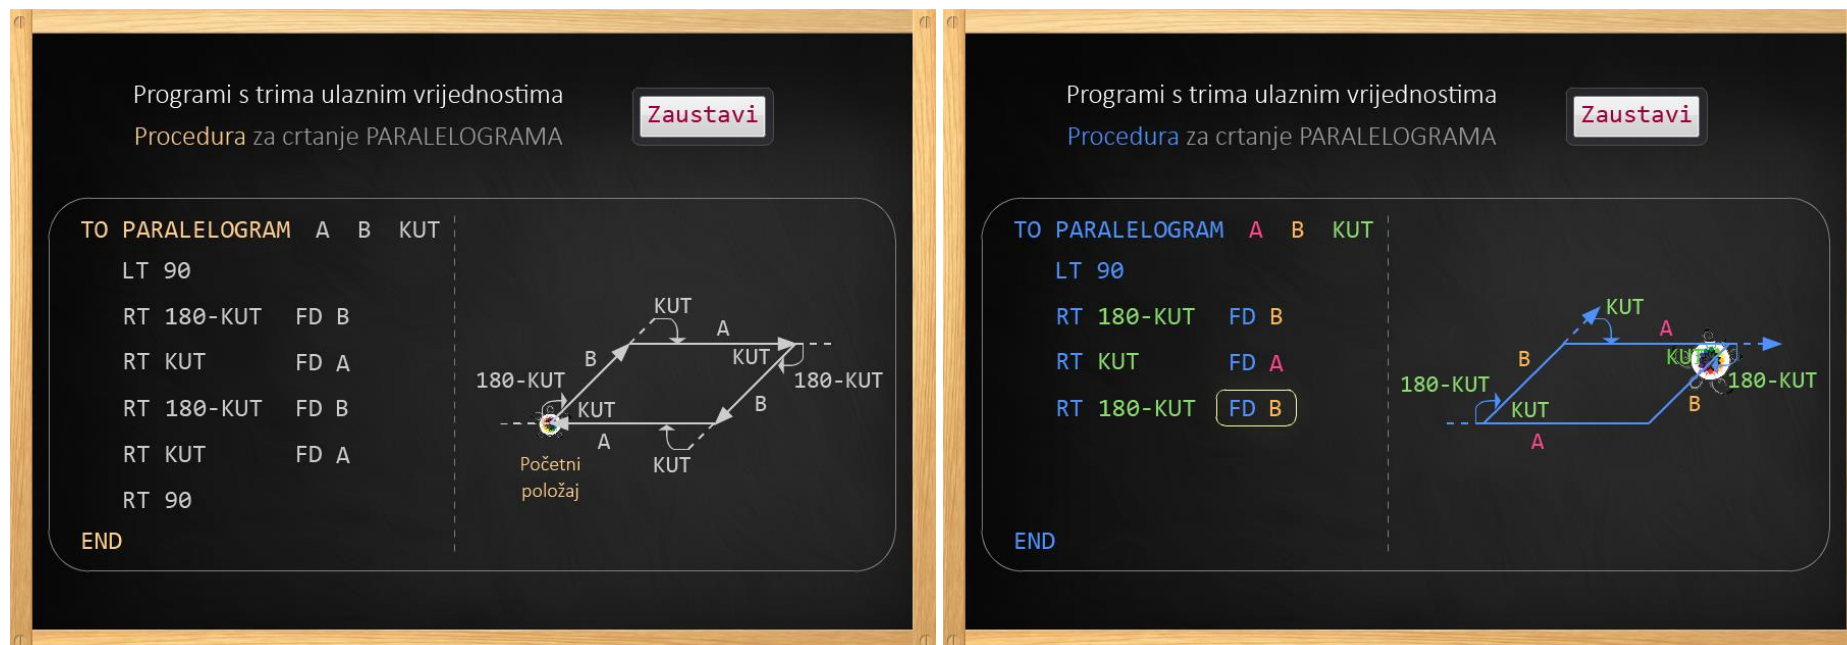


Slika 23. Treći slajd „Dvije Ulazne Vrijednosti“ (drugi dio) MIPL-a za drugu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno)

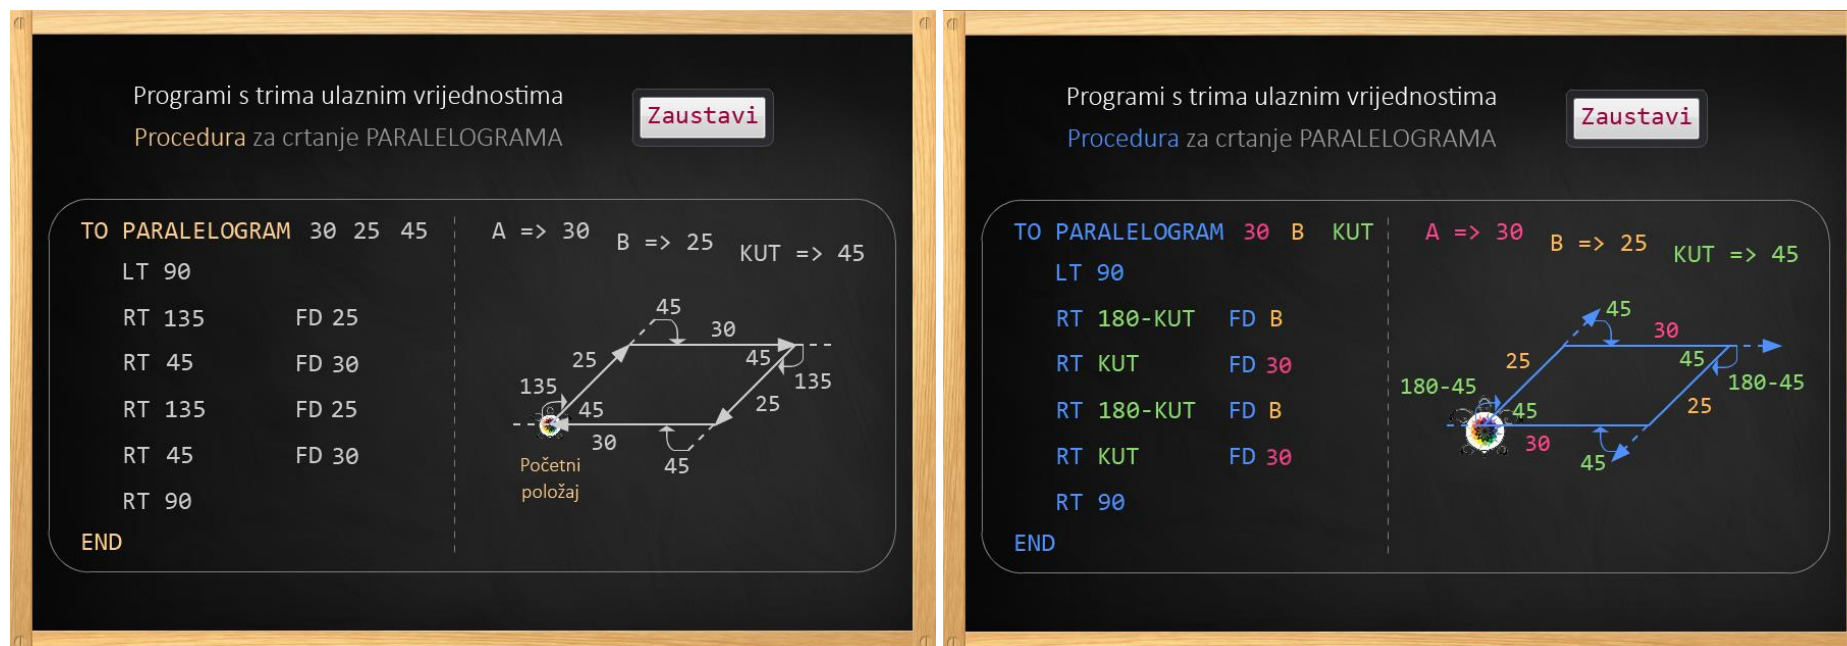
Tablica 19. Analiza načela MIPL-a za treći slajd druge nastavne cjeline

| Kontrolna skupina – KTMUZ načela | Eksperimentalna skupina – načelo RAŠČLANJIVANJA |
|--|---|
| <p>Načelo multimedija, načelo modaliteta, načelo vremenske usklađenosti (prilagođeni prirodni sadržaja poruke) – multimedijски prikaz sadrži pisani tekst, sliku i govoreni tekst, gdje su pisani tekst i slika vremenski usklađeni s govorenim tekstom. Pisani tekst sadrži prikaz procedura za crtanje geometrijskog lika pravokutnik s nepromjenjivim vrijednostima duljine stranica 50 i 25, te dvjema ulaznima vrijednostima duljine stranice A i B (60, 30). Slika sadrži statičnu vizualizaciju rezultata izvođenja poziva procedura „PRAVOKUTNIK“ i „PRAVOKUTNIK 60 30“. Govoreni tekst</p> | <p>Načelo animacije i interaktivnosti – (1) simultani prikaz animacije linearnog kretanja i rotacije kornjače (prema zadanim parametrima naredbi – 50 i 25) i izvođenja pojedinačne naredbe, pri čemu aktivacija interaktivnog elementa „Pokreni/Zaustavi“ pokreće ili zaustavlja animaciju; (2) dodatni interaktivni element za aktivaciju statičnog vizualnog prikaza geometrijskog lika pravokutnik kao</p> |

| | |
|--|--|
| <p>(naracija) sadrži najavu: (1) procedure s nepromjenjivim duljinama stranica od 50 i 25 piksela („Primjer procedure za iscrtavanje pravokutnika s nepromjenjivim duljinama stranica od 50 i 25 piksela. Pozivom procedure njenim imenom dobiva se izlazna vrijednost procedure, odnosno crtež pravokutnika“); (2) procedure s dvjema ulaznim vrijednostima A i B („Procedura za iscrtavanje pravokutnika s promjenjivim duljinama stranica A i B“).</p> | |
| <p>Načelo prostorne povezanosti – parametri naredbi (duljine stranica: 50 i 25; 60 i 30; A i B; kut rotacije: 90) postavljeni su na odgovarajuća mjesta u statičnim vizualnim prikazima geometrijskog lika pravokutnik.</p> | |
| <p>Načelo signalizacije – vizualno označavanje: (1) imena procedura i sadržajno relevantnih riječi (PRAVOKUTNIK, TO, END, Nepromjenjive, Promjenjive, Početni položaj) tipografskim signalom: svjetlo smeđa boja fonta; (2) zapisa i poziva procedura upotrebom zaobljenog pravokutnika bijele boje; (3) smjera kretanja kornjače na statičnim slikama pravokutnika (duljine stranica: 50 i 25; 60 i 30) upotrebom strelica bijele boje; (4) zapisa vrijednosti duljina stranica i kuta rotacije kornjače tipografskim signalom: bijela boja fonta.</p> | |
| <p>Načelo interaktivnosti – (1) interaktivni element za aktivaciju statičnog vizualnog prikaza geometrijskog lika pravokutnik kao rezultat pozivanja procedure „PRAVOKUTNIK 60 30“, pri čemu dolazi do zamjene varijabli A i B unutar zapisa procedure s vrijednostima 60 i 30; (2) interaktivni element „Pokreni/Zaustavi“ za pokretanje/zaustavljanje prikaza poruke.</p> | <p>rezultat pozivanja procedure „PRAVOKUTNIK 20 40“, pri čemu dolazi do zamjena varijabli A i B unutar zapisa procedure s vrijednostima 20 i 40.</p> <p>Načelo signalizacije – vizualno označavanje (1) imena procedura i sadržajno relevantnih znakova i riječi (PRAVOKUTNIK, TO, END, Procedura, FD, RT, 90) tipografskim signalom: plava boja fonta; (2) zapisa vrijednosti duljine stranica pravokutnika (50 i 25; 60 i 30; 20 i 40; A i B) unutar procedura i na statičnim vizualnim prikazima tipografskim signalima: ružičasta i žuta boja fonta; (3) zapisa i poziva procedura upotrebom zaobljenog pravokutnika bijele boje; (4) smjera kretanja kornjače na statičnoj slici pravokutnika (duljine stranica: 50 i 25) prikazanim linijama plave boje u formi „pojavljivanja“; (5) zapisa naredbi procedure „PRAVOKUTNIK“ (FD 25, RT 90, FD 50) upotrebom zaobljenog pravokutnika žute boje u formi „bljeskanja“; (6) zapisa vrijednosti duljine stranica (50, 25) i kuta rotacije kornjače (90) na pokretnoj slici iscrtavanja pravokutnika u formi „pojavljivanja“.</p> <p>Točke (4), (5) i (6) vizualnog označavanja su vremenski usklađene.</p> |
| <p>Konceptualni model</p> | <p>Objašnjenje procedure s dvjema ulazima vrijednostima.</p> <p>Potrebno predznanje: poznavanje karakteristika geometrijskog lika pravokutnik i osnovnih Logo naredbi za pomicanje i rotaciju kornjače (FD, RT).</p> |



Slika 24. Četvrti slajd „Više Ulaznih Vrijednosti“ (prvi dio) MIPL-a za drugu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno)



Slika 25. Četvrti slajd „Više Ulaznih Vrijednosti“ (drugi dio) MIPL-a za drugu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno)

Tablica 20. Analiza načela MIPL-a za četvrti slajd druge nastavne cjeline

| Kontrolna skupina – KTMUZ načela | Eksperimentalna skupina – načelo RAŠČLANJIVANJA |
|---|--|
| <p>Načelo multimedija, načelo modaliteta, načelo vremenske usklađenosti (prilagođeni prirodi sadržaja poruke) – multimedijски prikaz sadrži pisani tekst, sliku i govoreni tekst, gdje je pisani tekst vremenski usklađen s govorenim tekstom. Pisani tekst sadrži prikaz procedura za crtanje geometrijskog lika paralelograma s trima ulaznim vrijednostima (duljine stranice A i B, unutarnji šiljasti KUT). Slika sadrži statičnu vizualizaciju rezultata izvođenja poziva</p> | <p>Načelo animacije i interaktivnosti – simultani prikaz animacije linearnog kretanja i rotacije kornjače (prema zadanim parametrima naredbi – A, B, KUT), izvođenja pojedinačne naredbe u formi „pojavljivanja“ i vizualne signalizacije upotrebom zaobljenog pravokutnika žute boje u formi „bljeskanja“, pri čemu aktivacija interaktivnog elementa „Pokreni/Zaustavi“ pokreće ili zaustavlja animaciju.</p> |

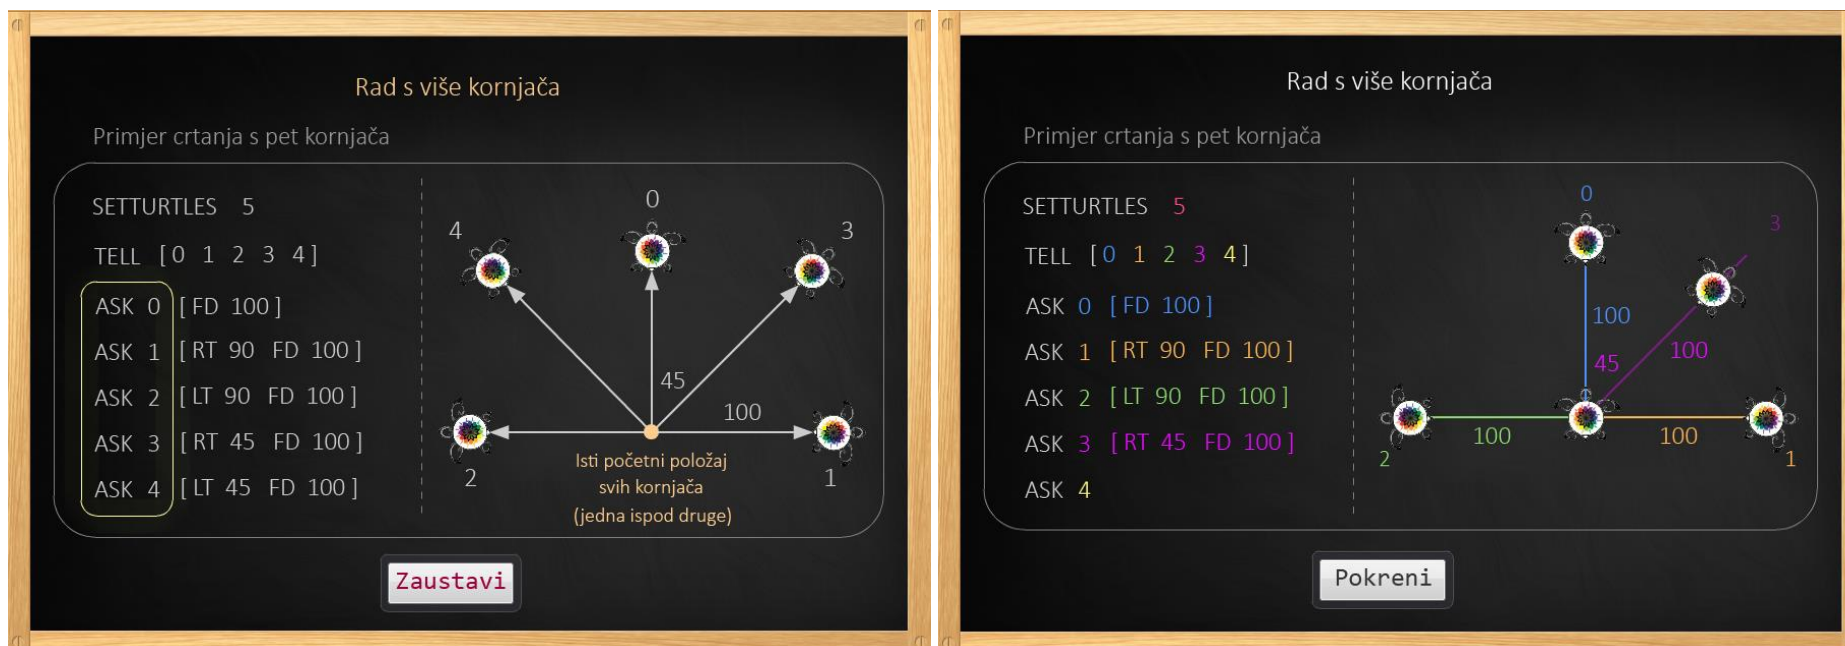
| | | |
|--|--|--|
| <p>procedura „PARALELOGRAM A B KUT“ i „PARALELOGRAM 30 25 45“. Govoreni tekst (naracija) sadrži najavu procedura s trima ulaznim vrijednostima („Procedura za iscrtavanje paralelograma sadrži tri ulazne vrijednosti: duljine stranica A i B, te vrijednost unutarnjeg šiljastog kuta. Paralelogram s duljinama stranica od 30 i 25 piksela, te unutarnjeg kuta od 45 stupnjeva“).</p> | | <p>Načelo signalizacije – vizualno označavanje (1) imena procedura i sadržajno relevantnih riječi (PARALELOGRAM, TO, END, Procedura, LT, RT, FD) tipografskim signalom: plava boja fonta; (2) zapisa vrijednosti duljine stranica (A i B; 30 i 25) i kutova rotacije kornjače (KUT i 180-KUT; 45 i 135) unutar procedura i na statičnim vizualnim prikazima tipografskim signalima: ružičasta, žuta i zelena boja fonta; (3) zapisa i poziva procedura upotrebom zaobljenog pravokutnika bijele boje; (4) zapisa ulaznih vrijednosti (A, B, KUT) upotrebom zaobljenog pravokutnika žute boje u formi „bljeskanja“; (5) smjera kretanja i rotacije kornjače na statičnoj slici paralelograma prikazanim linijama i upotrebom strelice plave boje u formi „pojavljivanja“; (6) zapisa naredbi procedure „PARALELOGRAM A B KUT“ u formi „pojavljivanja“ i upotrebom zaobljenog pravokutnika žute boje u formi „bljeskanja“; (7) zapisa procedure „PARALELOGRAM A B KUT“ upotrebom zaobljenog pravokutnika sive boje u formi „zatamnjenja“; (8) zapisa vrijednosti duljine stranice (A => 30, B => 25) i kutova rotacije kornjače (KUT => 45, 135) na odgovarajućem mjestu statične slike paralelograma u formi „pojavljivanja“, pri čemu dolazi do zamjena varijabli (A, B, KUT i 180-KUT) unutar zapisa procedure s vrijednostima 30, 25, 45 i 135.</p> <p>Točke (5) i (6) vizualnog označavanja su vremenski usklađene.</p> <p>Točka (8) vizualnog označavanja vremenski je usklađena s govorenim tekstom „Paralelogram s duljinama stranica od 30 i 25 piksela, te unutarnjeg kuta od 45 stupnjeva“.</p> |
| <p>Načelo prostorne povezanosti – parametri naredbi (duljine stranica: A i B; 30 i 25; kutovi rotacije: KUT i 180-KUT; 45 i 135) postavljeni su na odgovarajuća mjesta u statičnim vizualnim prikazima geometrijskog lika paralelogram.</p> | | |
| <p>Načelo signalizacije – vizualno označavanje: (1) imena procedura i sadržajno relevantnih riječi (PARALELOGRAM, TO, END, Procedura, Početni položaj) tipografskim signalom: svjetlo smeđa boja fonta; (2) zapisa procedura (programski kôd) i poziva procedura upotrebom zaobljenog pravokutnika bijele boje; (3) smjera kretanja i kuta rotacije kornjače na statičnim slikama paralelograma upotrebom strelica bijele boje; (4) zapisa vrijednosti duljina stranica (A i B; 30 i 25) i kutova rotacije kornjače (KUT i 180-KUT; 45 i 135) tipografskim signalom: bijela boja fonta; (5) zapisa ulaznih vrijednosti (A, B, KUT) upotrebom zaobljenog pravokutnika žute boje u formi „bljeskanja“; (6) zapisa procedure „PARALELOGRAM A B KUT“ upotrebom zaobljenog pravokutnika sive boje u formi „zatamnjenja“.</p> | | |
| <p>Načelo interaktivnosti – interaktivni element „Pokreni/Zaustavi“ za pokretanje/zaustavljanje prikaza poruke.</p> | | |
| <p>Konceptualni model</p> | <p>Objašnjenje procedure s trima ulaznim vrijednostima.</p> <p>Potrebno predznanje: poznavanje karakteristika geometrijskog lika paralelogram i osnovnih Logo naredbi za pomicanje i rotaciju kornjače (FD, RT, LT).</p> | |



Slika 26. Peti slajd „Višestruke Kornjače“ (prvi dio) MIPL-a za drugu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno)

Tablica 21. Analiza načela MIPL-a za peti slajd „Višestruke Kornjače“ (prvi dio) druge nastavne cjeline (kontrolna i eksperimentalna skupina)

| | |
|--|--|
| <p>Načelo multimedija, načelo modaliteta – multimedijски prikaz sadrži statičnu vizualizaciju kornjača u formi „pojavljivanja“ i tekst u pisanom obliku umjesto narativnom (poštivanje graničnog uvjeta za primjenu načela modaliteta: <i>nemogućnost zadržavanja informacija u radnoj memoriji za govoreni tekst predugačkog segmenta</i>).</p> <p>Načelo signalizacije – vizualno označavanje: (1) sadržajno relevantnih znakova i riječi tipografskim signalima: svjetlo smeđa (slika lijevo) i plava (slika desno) boja fonta; (2) zapisa brojeva kornjača (0, 1, 2...99) u formi „pojavljivanja“.</p> | |
| Konceptualni model | Navođenje osnovnih pojmova vezanih za rad s više kornjača u programskom jeziku Logo. |



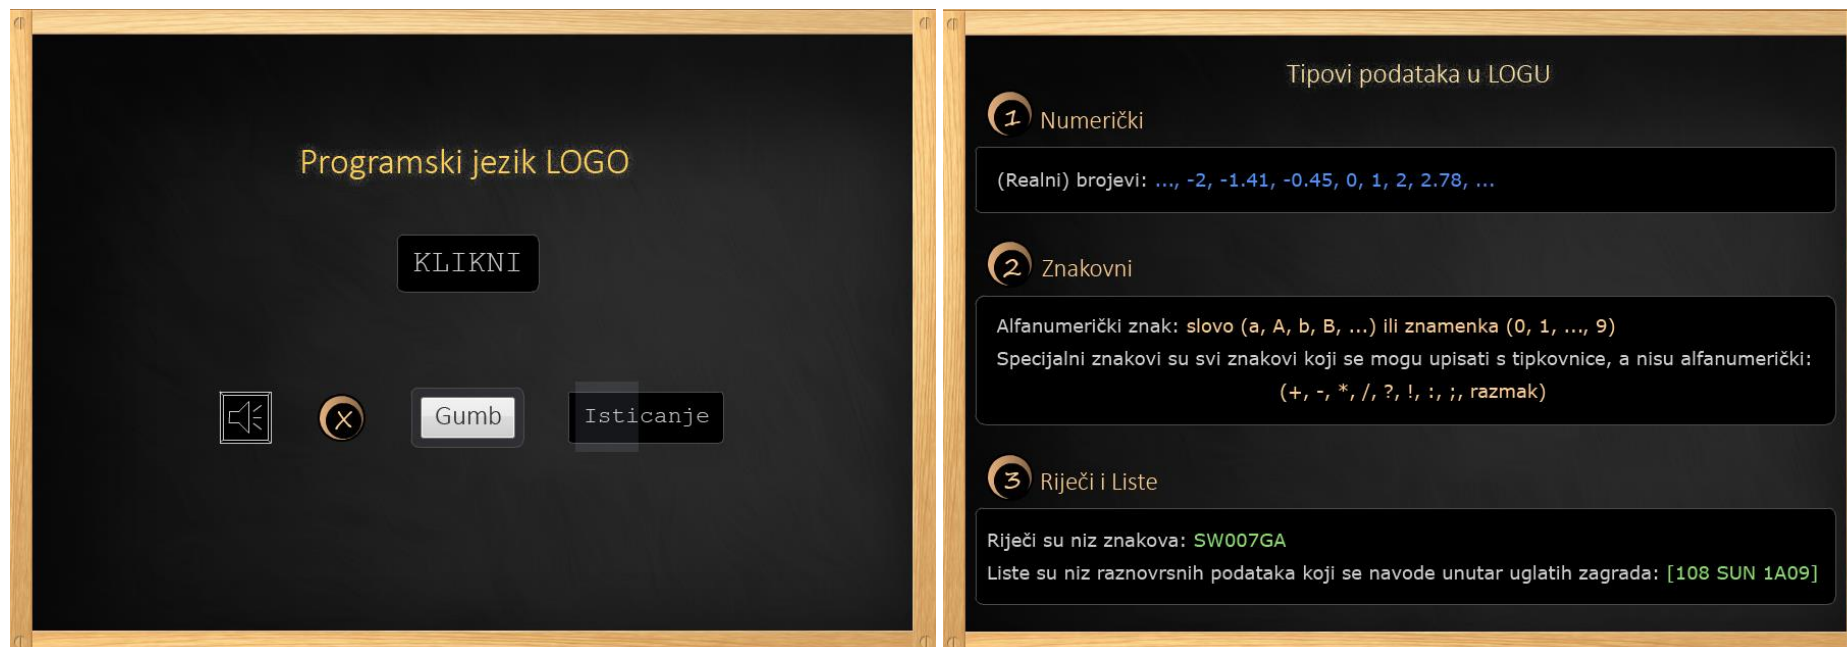
Slika 27. Peti slajd „Višestruke Kornjače“ (drugi dio) MIPL-a za drugu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno)

Tablica 22. Analiza načela MIPL-a za peti slajd (drugi dio) druge nastavne cjeline

| Kontrolna skupina – KTMUZ načela | Eksperimentalna skupina – načelo RAŠČLANJIVANJA |
|---|---|
| <p>Načelo multimedija, načelo modaliteta, načelo vremenske usklađenosti (prilagođeni prirodi sadržaja poruke) – multimedijски prikaz sadrži pisani tekst, sliku i govoreni tekst, gdje je vizualno označavanje pisanog teksta vremenski usklađeno s govorenim tekstom. Pisani tekst sadrži prikaz programskog kôda za rad s više kornjača. Slika sadrži statičnu vizualizaciju rezultata izvođenja programskog kôda. Govoreni tekst (naracija) sadrži objašnjenje pojedinačnih naredbi esencijalnih za rad s više kornjača: SETTURTLES, TELL, ASK („Pomoću SETTURTLES naredbe programer brojčano zadaje računalu</p> | <p>Načelo animacije i interaktivnosti – simultani prikaz animacije linearnog kretanja više kornjača (prema zadanim parametrima ASK naredbi) i pojedinačne ASK naredbe u formi „pojavljivanja“.</p> <p>Načelo signalizacije – vizualno označavanje (1) zapisa parametra SETTURTLES naredbe crvenom bojom u formi „bljeskanja“; (2)</p> |

| | | |
|--|---|--|
| <i>koliko kornjača želi koristiti. Program postavlja sve kornjače na isti početni položaj. Pomoću TELL naredbe program aktivira na rad one kornjače čiji su brojevi zapisani unutar uglatih zagrada. Pomoću ASK naredbi nultu, prvu, drugu, treću i četvrtu kornjaču tražimo da izvrše listu naredbi zapisanih unutar uglatih zagrada“).</i> | | <p>prikaza početnog položaja svih kornjača (tekst i slika) u formi „bljeskanja“; (3) zapisa parametara TELL naredbe u formi „pojavljivanja“ i simultanog prikaza istih parametara na odgovarajućim mjestima u formi „bljeskanja“ tipografskim signalima: plava, narančasta, zelena, ljubičasta i žuta boja fonta; (4) zapisa parametara ASK naredbi u formi „pojavljivanja“ plave, narančaste, zelene, ljubičaste i žute boje fonta; (5) simultanog prikaza ispisa ASK naredbi u formi „pojavljivanja“ unutar programskog kôda i odgovarajućih parametara ASK naredbi, te linearnih kretanja i rotacija kornjača u vizualnom dijelu prikaza (plava, narančasta, zelena, ljubičasta i žuta boja fonta).</p> <p>Sva vizualna označavanja vremenski su usklađena s govorenim tekstom.</p> |
| <p>Načelo prostorne povezanosti – parametri naredbi (brojevi kornjača – 0, 1, 2, 3 i 4; kut rotacije od 45 stupnjeva za treću i četvrtu kornjače, te pomaci svih kornjača za 100 piksela) postavljeni su na odgovarajuća mjesta u statičnom vizualnom prikazu.</p> | | |
| <p>Načelo signalizacije – vizualno označavanje: (1) sadržajno relevantnih riječi tipografskim signalom: svjetlosmeđa boja fonta; (2) zapisa programskog kôda i statične vizualizacije upotrebom zaobljenog pravokutnika bijele boje; (3) prikaza početnog položaja svih kornjača u formi kruga svjetlo smeđe boje; (4) zapisa pojedinačnih naredbi upotrebom zaobljenog pravokutnika žute boje u formi „bljeskanja“ što je vremenski usklađeno s govorenim tekstom.</p> | | |
| <p>Načelo interaktivnosti – interaktivni element „Pokreni/Zaustavi“ za pokretanje/zaustavljanje prikaza poruke.</p> | | |
| <p>Konceptualni model</p> | <p>Objašnjenje programskog kôda za rad s više kornjača.</p> <p>Potrebno predznanje: osnovne Logo naredbe za pomicanje i rotaciju kornjače (FD, RT, LT).</p> | |

3.4 MIPL treće nastavne cjeline



Slika 28. Uvodni slajd „Naslovna“ (slika lijevo) i prvi slajd „Tipovi Podataka“ (slika desno) MIPL-a za treću cjelinu (kontrolna i eksperimentalna skupina)

Tablica 23. Analiza načela MIPL-a za prvi slajd „Tipovi Podataka“ treće nastavne cjeline (kontrolna i eksperimentalna skupina)

| | |
|---|---|
| Načelo signalizacije – vizualno označavanje sadržajno relevantnih znakova i riječi multimedijskog prikaza tipografskim signalima: plava, narančasta i zelena boja fonta. | |
| Načelo interaktivnosti – interaktivni elementi (1, 2, 3) za aktivaciju pisanog teksta: tekstualno objašnjenje tipova podataka u programskom jeziku Logo. | |
| Konceptualni model | Objašnjenje tipova podataka u programskom jeziku Logo. |

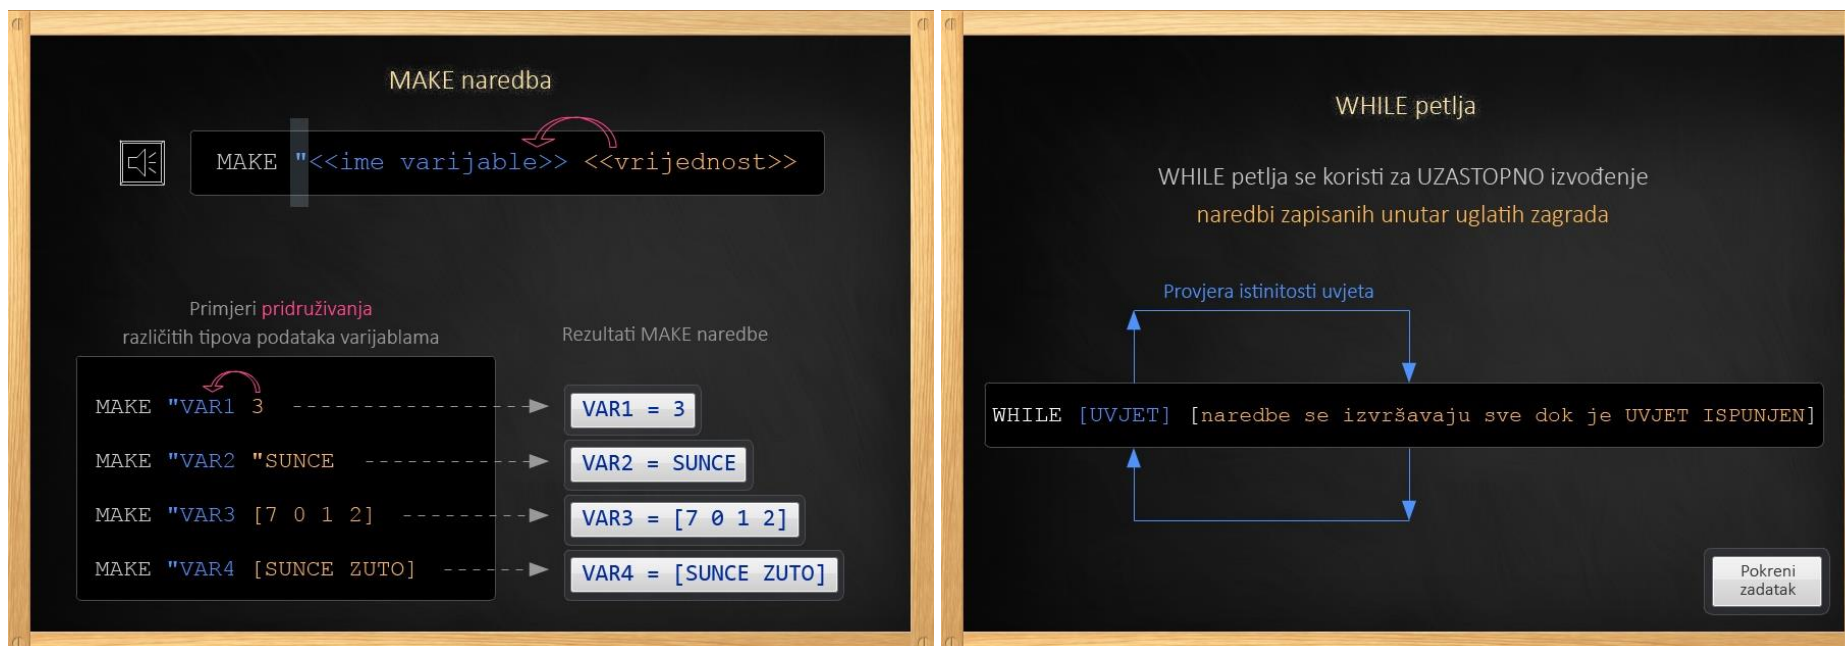


Slika 29. Drugi slajd „Rijeci & Liste 01“ (slika lijevo) i treći slajd „Rijeci & Liste 02“ (slika desno) MIPL-a za treću cjelinu (kontrolna i eksperimentalna skupina)

Tablica 24. Analiza načela MIPL-a za drugi i treći slajd treće nastavne cjeline (kontrolna i eksperimentalna skupina)

Načelo signalizacije – vizualno označavanje: (1) sadržajno relevantnih riječi (osnovne naredbe za rad sa riječima i listama) multimedijskog prikaza tipografskim signalima: narančasta (naredbe) i plava (parametri i rezultat izvođenja naredbi) boja fonta; (2) zapisa pojedinačne naredbe i primjer izvođenja za RIJEČ i LISTU upotrebom pravokutnika crne boje; (3) zapisa pojedinačne naredbe (FIRST, LAST, BF, BL, COUNT, ITEM, PRINT) upotrebom pravokutnika sive boje čijom se aktivacijom (prelazak grafičkog pokazivača) prikazuje objašnjenje naredbe; (4) prikaza odvajanja primjera izvođenja naredbi za RIJEČ i LISTU upotrebom isprekidane uspravne linije bijele boje; (5) zapisa navodnog znaka uz riječ „SUNCE“ u naredbi FIRST upotrebom pravokutnika sive boje čijom se aktivacijom (prelazak grafičkog pokazivača) prikazuje objašnjenje upotrebe znaka.

| | |
|--------------------|--|
| Konceptualni model | Objašnjenje osnovnih naredba za rad sa riječima i listama. |
|--------------------|--|



Slika 30. Četvrti slajd „MAKE naredba“ (slika lijevo) i peti slajd „WHILE petlja“ (prvi dio, slika desno) MIPL-a za treću cjelinu (kontrolna i eksperimentalna skupina)

Tablica 25. Analiza načela MIPL-a za četvrti slajd „MAKE naredba“ treće nastavne cjeline (kontrolna i eksperimentalna skupina)

Načelo vremenske usklađenosti, načelo prostorne povezanosti (prilagođeni prirodi sadržaja poruke) – multimedijски prikaz sadrži pisani tekst i govoreni tekst (naracija) koji prikazuje objašnjenja MAKE naredbe („Naredba MAKE pridružuje numeričku vrijednost ili znakovni niz varijabli“) i rezultate izvođenja naredbe za četiri različita primjera ulaznih vrijednosti („U varijablu jedan naredba MAKE pohranjuje numeričku vrijednost tri. U varijablu dva naredba MAKE pohranjuje znakovni niz ili riječ SUNCE. U varijablu tri naredba MAKE pohranjuje listu numeričkih vrijednosti [7 0 1 2]. U varijablu četiri naredba MAKE pohranjuje listu znakova ili riječi [SUNCE ZUTO].“). Govoreni tekst nije simultan s prikazom pisanog teksta već se nalazi u formi interaktivnih elemenata koji se aktiviraju prema izboru korisnika. Vizualno označavanje prostorno je integrirano sa sadržajno relevantnim dijelovima prikaza.

Načelo signalizacije – vizualno označavanje: (1) sadržajno relevantnih znakova i riječi multimedijskog prikaza tipografskim signalima: plava (ime varijabli MAKE naredbe), narančasta (vrijednosti varijabli MAKE naredbe) i ružičasta (riječ: „*pridruživanja*“) boja fonta; (2) zapisa sintakse MAKE naredbe upotrebom pravokutnika crne boje; (3) zapisa navodnog znaka uz izraz „<ime varijable>“ upotrebom pravokutnika sive boje čijom se aktivacijom (prelazak grafičkog pokazivača) prikazuje objašnjenje upotrebe znaka; (4) akcija pohranjivanja vrijednosti (broj 3) u varijablu VAR1 upotrebom strelice ružičaste boje; (5) zapisa četiriju primjera pridruživanja različitih vrsta podataka (numerički, riječi, liste) varijablama upotrebom pravokutnika crne boje, strelica ružičaste (pohranjivanje podatka) i sive (rezultati izvođenja naredbi) boje.

Načelo interaktivnosti – interaktivni elementi za aktivaciju verbalnih objašnjenja: (1) naredbe MAKE (simbol zvučnika); (2) rezultata izvođenja MAKE naredbe za četiri različita primjera ulaznih vrijednosti (VAR1, VAR2, VAR3, VAR4).

| | |
|---------------------------|---|
| Konceptualni model | <p align="center">Objašnjenje MAKE naredbe.</p> <p align="center">Potrebno predznanje: razumijevanje izjave pridruživanja (operator „=“) u procesu programiranja.</p> |
|---------------------------|---|

Tablica 26. Analiza načela MIPL-a za peti slajd „WHILE petlja“ (prvi dio) treće nastavne cjeline (kontrolna i eksperimentalna skupina)

Načelo signalizacije – vizualno označavanje: (1) sadržajno relevantnih riječi multimedijskog prikaza tipografskim signalima: narančasta (izrazi: „*naredbi zapisanih unutar uglatih zagrada*“ i „*naredbe se izvršavaju sve dok je UVJET ISPUNJEN*“) i plava (izrazi: „*UVJET*“ i „*Provjera istinitosti uvjeta*“) boja fonta; (2) zapisa sintakse WHILE petlje upotrebom pravokutnika crne boje; (3) akcije provjere istinitosti uvjeta upotrebom strelica plave boje.

Načelo interaktivnosti – interaktivni element (simbol zvučnika) za pokretanje zadataka.

| | |
|---------------------------|----------------------------------|
| Konceptualni model | Objašnjenje WHILE petlje. |
|---------------------------|----------------------------------|

Primjer WHILE petlje koja ispisuje PARNE brojeve sve dok je ispunjen uvjet: $X < 5$

```
MAKE "A 0
MAKE "X 1
WHILE [X < 5] [PR A (MAKE "A A+2) (MAKE "X X+1) ]
```

Vrijednost varijable A povećava se za 2

Rezultat izvođenja WHILE petlje (PR A)

| | |
|----------------------------|---|
| Prvi prolaz kroz petlju | 0 |
| Drugi prolaz kroz petlju | 2 |
| Treći prolaz kroz petlju | 4 |
| Četvrti prolaz kroz petlju | 6 |

Povratak na definiciju

Primjer WHILE petlje koja ispisuje PARNE brojeve sve dok je ispunjen uvjet: $X < 5$

```
MAKE "A 0
MAKE "X 1
WHILE [X < 5] [PR A (MAKE "A A+2) (MAKE "X X+1) ]
```

Unutrašnjost WHILE petlje

X = 1

X = 2 [2 < 5] [PR 2 (MAKE "A 2+2) (MAKE "X 2+1)] → 2

X = 3

X = 4

X = 5

Rezultat (PR A)

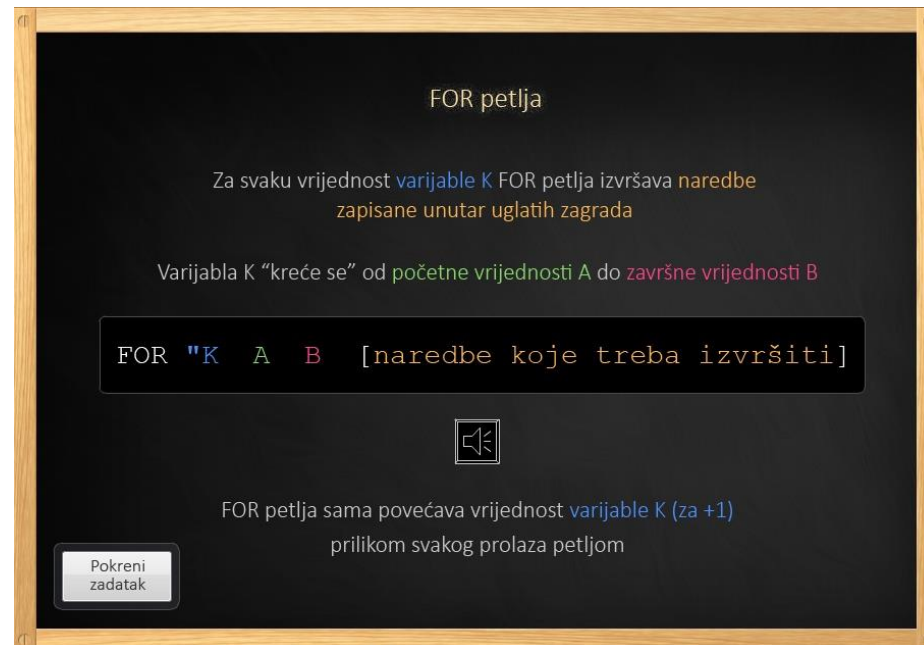
Povratak na definiciju

Slika 31. Peti slajd „WHILE petlja“ (drugi dio) MIPL-a za treću cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno)

Tablica 27. Analiza načela MIPL-a za peti slajd „WHILE petlja“ (drugi dio) treće nastavne cjeline

| Kontrolna skupina – KTMUZ načela | Eksperimentalna skupina – načelo RAŠČLANJIVANJA |
|---|--|
| <p>Načelo signalizacije – vizualno označavanje:</p> <p>(1) sadržajno relevantnih znakova i riječi multimedijskog prikaza tipografskim signalima: plava (ime varijabli i uvjet WHILE petlje), narančasta (vrijednosti varijabli WHILE petlje) i ružičasta (riječ: „ispunjen“)</p> | <p>Načelo vremenske usklađenosti, načelo prostorne povezanosti (prilagođeni prirodi sadržaja poruke) – multimedijski prikaz sadrži pisani tekst (programski kôd) primjera WHILE petlje i govoreni tekst (naracija) s objašnjenjima izvođenja prva dva koraka petlje („U prvom prolazu kroz WHILE petlju, za $x = \text{jedan}$, postavljeni uvjet je ispunjen i naredba PRINT ispisuje vrijednost varijable A koja iznosi nula. Potom, naredba MAKE povećava vrijednost varijable A za dva i vrijednost varijable X za jedan. U drugom prolazu kroz WHILE petlju, za $x = \text{dva}$, postavljeni uvjet je ispunjen i naredba PRINT ispisuje vrijednost varijable A koja iznosi dva. Potom, naredba MAKE povećava vrijednost varijable A za dva i vrijednost varijable X</p> |

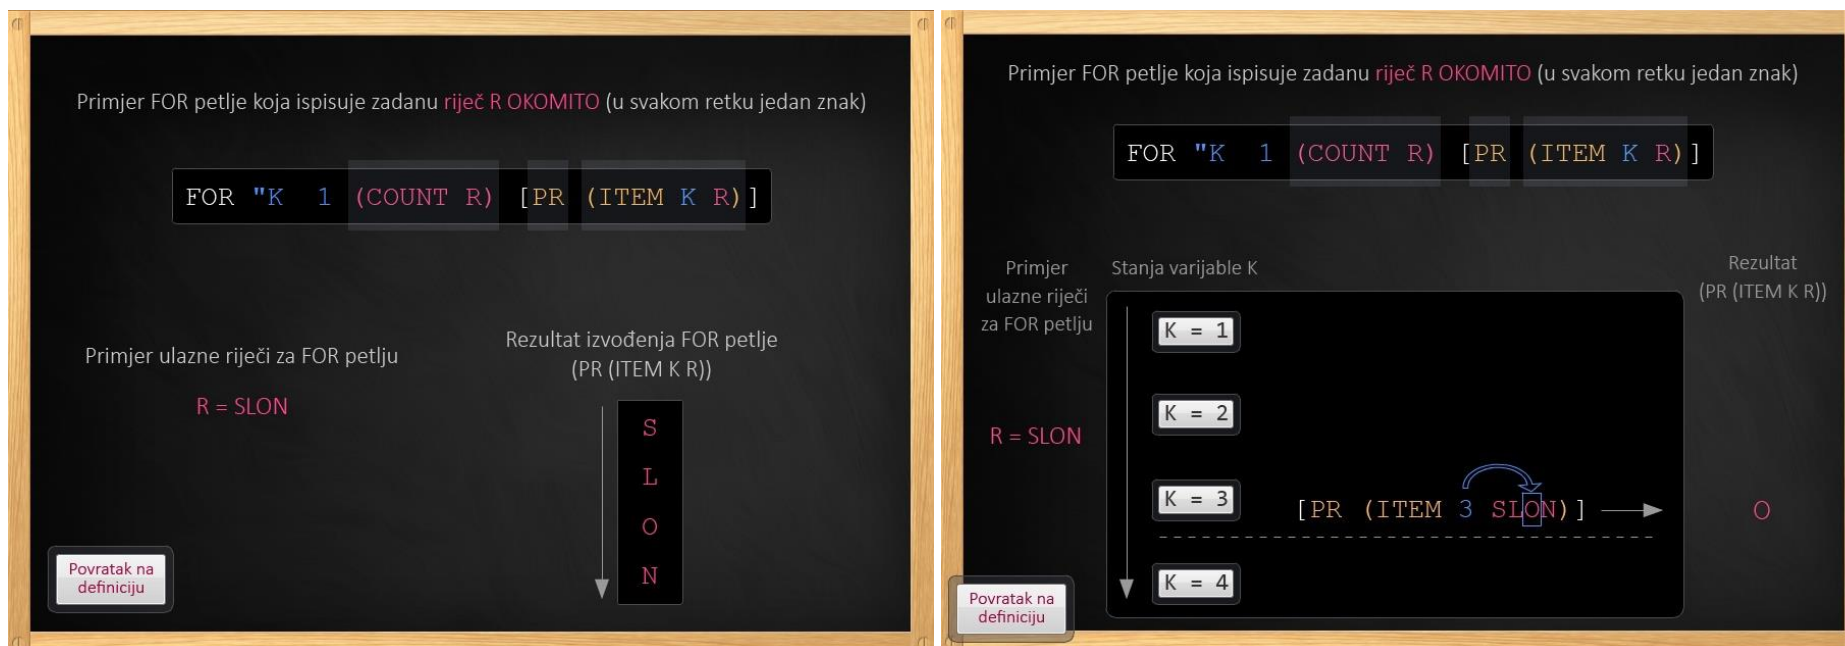
| | |
|--|--|
| <p>boja fonta; (2) zapisa programskog kôda i rezultata njegova izvođenja upotrebom pravokutnika crne boje; (3) zapisa pojedinačne naredbe upotrebom pravokutnika sive boje čijom se aktivacijom (prelazak grafičkog pokazivača) prikazuje objašnjenje naredbe; (4) zapisa niza izlaznih vrijednosti programskog kôda WHILE petlje (četiri prolaza) upotrebom strelice bijele boje.</p> <p>Vizualno označavanje prostorno je integrirano sa sadržajno relevantnim dijelovima prikaza (načelo prostorne povezanosti).</p> | <p>za jedan“). Govoreni tekst vremenski je usklađen sa vizualnom prikazom objašnjenja izvođenja prva dva koraka WHILE petlje i nalazi se u formi interaktivnih elemenata koji se aktiviraju prema izboru korisnika.</p> <p>Načelo signalizacije – vizualno označavanje: (1) sadržajno relevantnih znakova i riječi multimedijskog prikaza tipografskim signalima: plava (ime varijabli i uvjet WHILE petlje), narančasta (vrijednosti varijabli WHILE petlje) i ružičasta (riječ: „ispunjen“) boja fonta; (2) zapisa programskog kôda i rezultata njegova izvođenja („unutrašnjost“ WHILE petlje) upotrebom pravokutnika crne boje; (3) zapisa pojedinačne naredbe upotrebom pravokutnika sive boje čijom se aktivacijom (prelazak grafičkog pokazivača) prikazuje objašnjenje naredbe; (4) zapisa pojedinačnih koraka u izvođenju WHILE petlje (vrijednosti varijabli A i X, stanje WHILE petlje i pripadajući rezultat izvođenja petlje); (5) akcije pohranjivanja vrijednosti u varijable (A, X) MAKE naredbe upotrebom strelice žute boje.</p> <p>Vizualno označavanje prostorno je integrirano sa sadržajno relevantnim dijelovima prikaza.</p> <p>Načelo interaktivnosti – interaktivni elementi za aktivaciju: (1) rezultata izvođenja pojedinačnih koraka WHILE petlje (X = 1; X = 2; X = 3; X = 4; X = 5); (2) verbalnih objašnjenja izvođenja prva dva koraka WHILE petlje (X = 1; X = 2).</p> |
| <p>Konceptualni model</p> | <p>Objašnjenje WHILE petlje.</p> <p>Potrebno predznanje: osnovno razumijevanje programske strukture WHILE petlje u procesu programiranja.</p> |



Slika 32. Šesti slajd „FOR petlja“ (prvi dio) MIPL-a za treću cjelinu (kontrolna i eksperimentalna skupina)

Tablica 28. Analiza načela MIPL-a za šesti slajd „FOR petlja“ (prvi dio) treće nastavne cjeline (kontrolna i eksperimentalna skupina)

| | |
|---|-------------------------|
| <p>Načelo signalizacije – vizualno označavanje: (1) sadržajno relevantnih znakova i riječi multimedijskog prikaza tipografskim signalima: plava („varijable K“, „K“ i „varijable K (za +1)“), narančasta (izrazi: „naredbe zapisane unutar uglatih zagrada“ i „naredbe koje treba izvršiti“), zelena („početne vrijednosti A“ i „A“) i ružičasta („završne vrijednosti B“ i „B“) boja fonta; (2) zapisa sintakse FOR petlje upotrebom pravokutnika crne boje.</p> | |
| <p>Načelo interaktivnosti – interaktivni element (simbol zvučnika) za verbalno objašnjenje FOR petlje: „Varijabla K unutar FOR petlje kreće se od početne vrijednosti A do završne vrijednosti B. Naredbe unutar FOR petlje izvršavaju se sve dok varijabla K ne postigne završnu vrijednost B“.</p> | |
| Konceptualni model | Objašnjenje FOR petlje. |

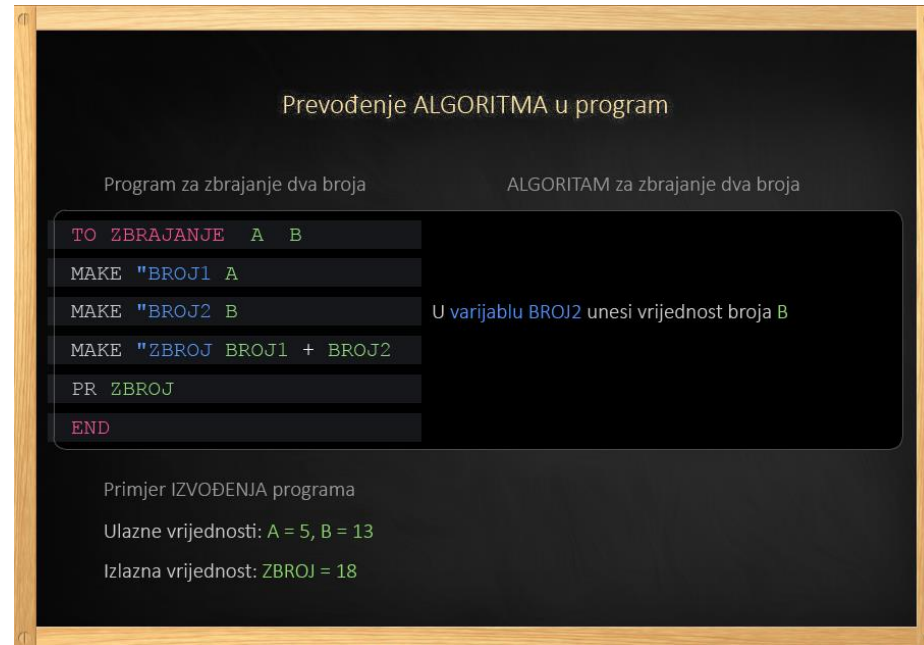


Slika 33. Šesti slajd „FOR petlja“ (drugi dio) MIPL-a za treću cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno)

Tablica 29. Analiza načela MIPL-a za šesti slajd „FOR petlja“ (drugi dio) treće nastavne cjeline

| Kontrolna skupina – KTMUZ načela | Eksperimentalna skupina – načelo RAŠČLANJIVANJA |
|---|---|
| <p>Načelo signalizacije – vizualno označavanje: (1) sadržajno relevantnih znakova i riječi multimedijiskog prikaza tipografskim signalima: ružičasta („riječ R OKOMITO“, „(COUNT R)“, „R = SLON“ i „R“), plava („K“ i „K“) i narančasta („PR (ITEM ...)“) boja fonta; (2)</p> | <p>Načelo vremenske usklađenosti, načelo prostorne povezanosti (prilagođeni prirodi sadržaja poruke) – multimedijски prikaz sadrži pisani tekst (programski kôd) primjera FOR petlje i govoreni tekst (naracija) s objašnjenjima izvođenja prva dva koraka petlje („U prvom prolazu kroz FOR petlju, za k = jedan, naredba ITEM vraća PRVI znak u riječi SLON. Naredba PRINT ispisuje rezultat naredbe ITEM odnosno slovo S. U drugom prolazu kroz FOR petlju, za k = dva, naredba ITEM vraća DRUGI znak u riječi SLON. Naredba PRINT ispisuje rezultat naredbe ITEM odnosno slovo L“). Govoreni tekst vremenski je usklađen sa vizualnom prikazom objašnjenja izvođenja prva dva koraka FOR petlje i nalazi</p> |

| | |
|--|--|
| <p>zapisa programskog kôda i rezultata njegova izvođenja upotrebom pravokutnika crne boje; (3) zapisa pojedinačne naredbe upotrebom pravokutnika sive boje čijom se aktivacijom (prelazak grafičkog pokazivača) prikazuje objašnjenje naredbe; (4) zapisa niza izlaznih vrijednosti programskog kôda FOR petlje (četiri prolaza) upotrebom strelice bijele boje.</p> <p>Vizualno označavanje prostorno je integrirano sa sadržajno relevantnim dijelovima prikaza (načelo prostorne povezanosti).</p> | <p>se u formi interaktivnih elemenata koji se aktiviraju prema izboru korisnika.</p> <p>Načelo signalizacije – vizualno označavanje: (1) sadržajno relevantnih znakova i riječi multimedijskog prikaza tipografskim signalima: ružičasta („<i>riječ R OKOMITO</i>“, „(<i>COUNT R</i>)“, „<i>R = SLON</i>“, „<i>R</i>“ i „<i>SLON</i>“, „<i>S</i>“, „<i>L</i>“, „<i>O</i>“, „<i>N</i>“), plava („<i>K</i>“, „<i>K</i>“ i vrijednosti varijable K) i narančasta („<i>PR (ITEM ...)</i>“) boja fonta; (2) zapisa programskog kôda i rezultata njegova izvođenja („unutrašnjost“ FOR petlje) upotrebom pravokutnika crne boje; (3) zapisa pojedinačne naredbe upotrebom pravokutnika sive boje čijom se aktivacijom (prelazak grafičkog pokazivača) prikazuje objašnjenje naredbe; (4) zapisa pojedinačnih koraka u izvođenju FOR petlje (vrijednosti varijable K, stanje FOR petlje i pripadajući rezultat izvođenja petlje); (5) akcije djelovanja naredbe ITEM nad riječi SLON upotrebom strelice plave boje.</p> <p>Vizualno označavanje prostorno je integrirano sa sadržajno relevantnim dijelovima prikaza.</p> <p>Načelo interaktivnosti – interaktivni elementi za aktivaciju: (1) rezultata izvođenja pojedinačnih koraka FOR petlje (K = 1; K = 2; K = 3; K = 4); (2) verbalnih objašnjenja izvođenja prva dva koraka FOR petlje (K = 1; K = 2).</p> |
| <p>Konceptualni model</p> | <p>Objašnjenje FOR petlje.</p> <p>Potrebno predznanje: osnovno razumijevanje programske strukture FOR petlje u procesu programiranja.</p> |

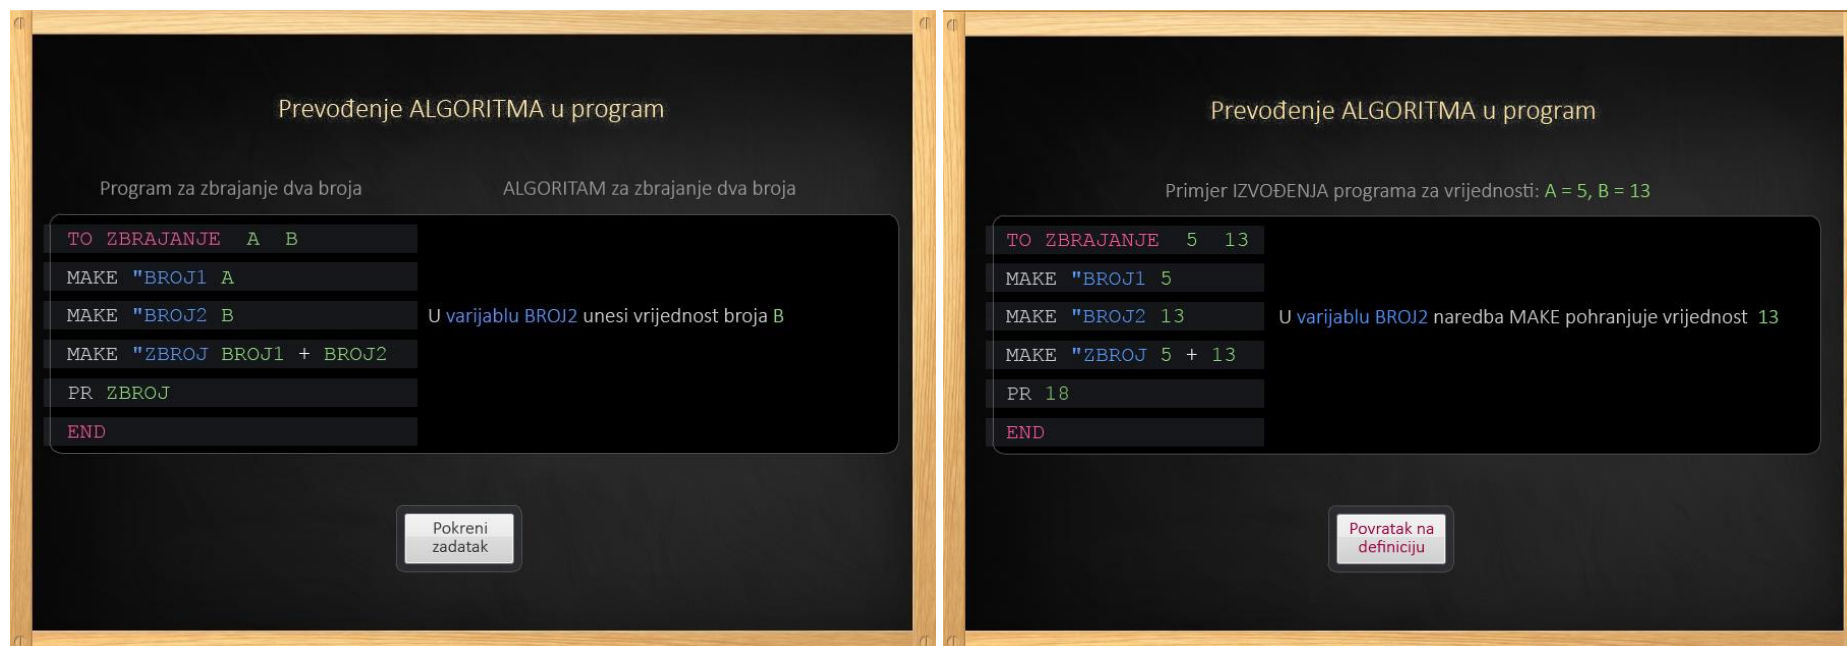


Slika 34. Sedmi slajd „Algoritmi“ MIPL-a za treću cjelinu – kontrolna skupina

Tablica 30. Analiza načela MIPL-a za sedmi slajd „Algoritmi“ treće nastavne cjeline (kontrolna skupina)

Načelo signalizacije – vizualno označavanje: (1) sadržajno relevantnih znakova i riječi multimedijskog prikaza tipografskim signalima: ružičasta (ključne riječi procedure: *TO* i *END*; ime procedure: *ZBRAJANJE*), plava (varijable: *BROJ1*, *BROJ2* i *ZBROJ*) i zelena (vrijednosti varijabli: *A*, *B*, *BROJ1*, *BROJ2* i *ZBROJ*) boja fonta; (2) zapisa pojedinačne linije programa upotrebom pravokutnika sive boje čijom se aktivacijom (prelazak grafičkog pokazivača) prikazuje odgovarajuće algoritamsko objašnjenje.

| Konceptualni model | <p>Objašnjenje algoritma za zbrajanje dva broja.</p> <p>Potrebno predznanje: poznavanje pojma „ALGORITAM“ u procesu programiranja.</p> |
|--------------------|--|
|--------------------|--|



Slika 35. Sedmi slajd „Algoritmi“ (prvi i drugi dio) MIPL-a za treću cjelinu – eksperimentalna skupina

Tablica 31. Analiza načela MIPL-a za sedmi slajd „Algoritmi“ (prvi i drugi dio) treće nastavne cjeline (eksperimentalna skupina)

Načelo signalizacije – vizualno označavanje: (1) sadržajno relevantnih znakova i riječi multimedijskog prikaza tipografskim signalima: ružičasta (ključne riječi procedure: *TO* i *END*; ime procedure *ZBRAJANJE*), plava (varijable *BROJ1*, *BROJ2* i *ZBROJ*) i zelena (vrijednosti varijabli *A* (5), *B* (13), *BROJ1* (5), *BROJ2* (13) i *ZBROJ* (18)) boja fonta; (2) zapisa pojedinačne linije programa upotrebom pravokutnika sive boje čijom se aktivacijom (prelazak grafičkog pokazivača) prikazuje odgovarajuće algoritamsko objašnjenje za numeričke vrijednosti varijabli (*A* = 5, *B* = 13, *ZBROJ* = 18).

| Konceptualni model | Objašnjenje algoritma za zbrajanje dva broja. |
|--------------------|---|
|--------------------|---|

4 METODOLOGIJA

4.1 Predmet istraživanja

Predmet ovog istraživanja bio je eksperimentalno provjeriti učinkovitost *multimedijske instruktivne poruke za programski jezik Logo* (MIPL), razvijene prema KTMUZ, kao *konceptualnog modela* za usvajanje osnovnih pojmova programskog jezika Logo. Uloga *konceptualnog modela* bila je potaknuti i usmjeriti ispitanike na proces aktivne izgradnje kognitivnog niza uzročno-posljedičnih veza između odabranih verbalnih i vizualnih komponenti multimedijskog prikaza koje opisuju određeni programski koncept ili strukturu, te izgradnje mentalnih veza između verbalnog i slikovnog modela i njihovih međusobnih relacija u *integrirani mentalni model programskog koncepta ili strukture*. Razumijevanje uzročno-posljedičnih veza odnosno logičkog slijeda radnji obuhvaća sposobnost mentalnog simuliranja i predviđanja rada programa (Narayanan, N. H. i Hegarty, M., 2002).

4.2 Cilj i hipoteze istraživanja

Cilj ovom istraživanju bio je ispitati učinkovitost *multimedijske instruktivne poruke za programski jezik Logo* (MIPL), kod studenata razredne nastave, budućih učitelja informatike.

Radi ispitivanja razlika u zapamćivanju i razumijevanju sadržaja razvijen je obrazovni sadržaj kojeg čine osnovni pojmovi odabranih nastavnih tema programskog jezika Logo, u formi multimedijske instruktivne poruke utemeljene na osam osnovnih načela (*načelo multimedija, načelo prostorne povezanosti, načelo vremenske usklađenosti, načelo koherentnosti, načelo modaliteta, načelo zalihosnosti, načelo individualnih razlika, načelo signalizacije*) i jednim naprednim načelom (*načelo animacije i interaktivnosti*) *kognitivne teorije multimedijskog usvajanja znanja* (kontrolna skupina), te s nadopunjenim načelom *rašćlanjivanja modela kognitivnog procesa multimodalnog razumijevanja* (eksperimentalna skupina).

Tri glavne hipoteze istraživanja:

(H1) Studenti koji koriste multimedijsku instruktivnu poruku s primjenom načela *rašćlanjivanja* postižu bolje rezultate pri rješavanju niza zadataka objektivnog tipa u zapamćivanju i razumijevanju sadržaja, nego studenti koji koriste poruku bez primjene načela *rašćlanjivanja*.

(H2) Studenti koji koriste multimedijску instruktivnu poruku s primjenom načela raščlanjivanja postižu bolje rezultate pri rješavanju niza zadataka objektivnog tipa u zapamćivanju i razumijevanju sadržaja za koji je izlazna vrijednost **geometrijska** vrsta podataka, nego studenti koji koriste poruku bez primjene načela raščlanjivanja.

(H3) Studenti koji koriste multimedijску instruktivnu poruku s primjenom načela raščlanjivanja postižu bolje rezultate pri rješavanju niza zadataka objektivnog tipa u zapamćivanju i razumijevanju sadržaja za koji je izlazna vrijednost **negeometrijska** vrsta podataka, nego studenti koji koriste poruku bez primjene načela raščlanjivanja.

4.3 Uzorak

U istraživanju su sudjelovali studenti treće, četvrte i pete godine studija Učiteljskog fakulteta Sveučilišta u Zagrebu (tablica 32). Istraživanje je provedeno na ciljanom uzorku od 98 ispitanika razredne nastave, modula informatike, u Zagrebu (45) i Čakovcu (53). Od 45 ispitanika u Zagrebu njih 22 je prema abecednom redu dodijeljeno kontrolnoj skupini (MIPL bez primjene načela raščlanjivanja), a 23 iz ostatka abecednog popisa studenata eksperimentalnoj skupini (MIPL s primjenom načela raščlanjivanja). Od 53 ispitanika u Čakovcu njih 26 je prema abecednom redu dodijeljeno kontrolnoj skupini, a 27 iz ostatka abecednog popisa studenata eksperimentalnoj skupini. Sveukupno u kontrolnoj skupini bilo je 48 ispitanika, a u eksperimentalnoj 50 ispitanika.

Tablica 32. Uzorak

| Godina studija | Lokacija | Skupina | | | | Ukupno |
|----------------|----------|-----------------|-------|-----------|-------|--------|
| | | Eksperimentalna | | Kontrolna | | |
| | | N | % | N | % | |
| 3 | Zagreb | 6 | 50,0% | 6 | 50,0% | 12 |
| | Čakovec | 8 | 50,0% | 8 | 50,0% | 16 |
| | Ukupno | 14 | 50,0% | 14 | 50,0% | 28 |
| 4 | Zagreb | 7 | 53,8% | 6 | 46,2% | 13 |
| | Čakovec | 9 | 50,0% | 9 | 50,0% | 18 |
| | Ukupno | 16 | 51,6% | 15 | 48,4% | 31 |
| 5 | Zagreb | 10 | 50,0% | 10 | 50,0% | 20 |
| | Čakovec | 10 | 52,6% | 9 | 47,4% | 19 |
| | Ukupno | 20 | 51,3% | 19 | 48,7% | 39 |
| Ukupno | Zagreb | 23 | 51,1% | 22 | 48,9% | 45 |
| | Čakovec | 27 | 50,9% | 26 | 49,1% | 53 |
| | Ukupno | 50 | 51,0% | 48 | 49,0% | 98 |

4.4 Metoda istraživanja

U svrhu provjere hipoteza, da će se primjenom načela raščlanjivanja u multimedijskoj instruktivnoj poruci poboljšati usvajanje i primjena znanja programiranja u Logo jeziku, provedeno je istraživanje uz primjenu eksperimenta s paralelnim grupama.

Za statističku obradu podataka i interpretaciju rezultata korištene su metode deskriptivne statistike (aritmetička sredina, standardna devijacija, medijan, asimetrija distribucije, spljoštenost, Kolmogorov-Smirnovljev test normaliteta distribucije, p-statistička značajnost KS testa), kako bi se prema tipu distribucije odredili postupci testiranja. Za testiranje su korišteni Mann-Whitneyev test kao neparametrijska alternativa t-testu i Kruskal-Wallisov test kao neparametrijska alternativa analizi varijance. Za ostale analize i usporedbe korišteni su χ^2 – test, proporcije (relativne vrijednosti) i testovi proporcije, te koeficijent veličine efekta (r) kao pokazatelj veličine rezultata (razlike, povezanosti) u odabranom uzroku. Podatci dobiveni eksperimentalnim programom obrađeni su statistički uz pomoć programa MS Office Excel i primjenom statističkog paketa SPSS.

4.5 Eksperimentalni program

4.5.1 Materijali i tehnička oprema

U sklopu eksperimentalnog istraživanja radi ispitivanja razlika u zapamćivanju i razumijevanju sadržaja korišten je obrazovni sadržaj u formi multimedijske instruktivne poruke za učenje osnovnih pojmova iz programskog jezika Logo (MIPL), koji je sačinjen od 9 odabranih nastavnih tema klasificiranih prema vrsti podatka izlazne vrijednosti programa (geometrijski/negeometrijski): *Osnovne naredbe programskog jezika; Ponavljanje niza naredbi (REPEAT petlja); Uporaba petlje za crtanje niza likova; Ulazne vrijednosti procedura (MAKE naredba); Uporaba više ulaznih vrijednosti; Crtanje kocke i kvadra, Višestruke kornjače; Tipovi podataka (numerički, znakovni, liste); Algoritmi koji koriste različite tipove podataka.* Nastavne teme preuzete su iz Nastavnog plana i programa za osnovnu školu za peti i šesti razred osnovne škole (MZOŠ, 2006), te iz udžbenika Terrapin Logo (Kniewald, I., 2005). MIPL je razvijena pomoću računalnog autorskog alata *Adobe Captivate*. U razvoju MIPL-a primijenjeno je osam osnovnih načela (*načelo multimedija, načelo prostorne povezanosti, načelo vremenske usklađenosti, načelo koherentnosti, načelo modaliteta, načelo zalihosnosti, načelo individualnih razlika, načelo signalizacije*) i jedno

napredno načelo (*načelo animacije i interaktivnosti*) *kognitivne teorije multimedijskog usvajanja znanja* (kontrolna skupina) (Mayer, R. E., 2001, 2005, 2014a), s nadopunjenim načelom raščlanjivanja prema *modelu kognitivnog procesa multimodalnog razumijevanja* (eksperimentalna skupina), (Narayanan, N. H. i Hegarty, M., 2002). Multimedijски sadržaj za tri tjedna istraživanja detaljno je prikazan i analiziran u trećem poglavlju.

Tiskani materijali korišteni u istraživanju:

- **Predtest** u svrhu dobivanja osnovnih informacija o ispitaniku: rod, mjesto (grad) studiranja, godina studija (dob ispitanika), općenito predznanje iz poznavanja programskih jezika stečeno kroz osnovnu i srednju školu, fakultet i izvannastavne aktivnosti (5 pitanja), te subjektivne procjene znanja iz programiranja i poznavanja osnovnih pojmova Logo jezika (3 pitanja u formi Likertove ljestvice od 5 stupnjeva). Predtest je primijenjen jednom, prije početka eksperimentalnog istraživanja. Vidi prilog A.
- **Zadatci objektivnog tipa za prvi tjedan istraživanja** u svrhu mjerenja zapamćivanja (3 zadatka) i razumijevanja (2 zadatka) sadržaja iz nastavnih tema: *Osnovne naredbe programskog jezika; Ponavljanje niza naredbi (REPEAT petlja); Uporaba petlje za crtanje niza likova*. Vidi prilog B.
- **Zadatci objektivnog tipa za drugi tjedan istraživanja** u svrhu mjerenja zapamćivanja (4 zadatka) i razumijevanja (2 zadatka) sadržaja iz nastavnih tema: *Ulazne vrijednosti procedura (MAKE naredba); Uporaba više ulaznih vrijednosti; Crtanje kocke i kvadra; Višestruke kornjače*. Vidi prilog C.
- **Zadatci objektivnog tipa za treći tjedan istraživanja** u svrhu mjerenja zapamćivanja (3 zadatka) i razumijevanja (3 zadatka) sadržaja iz nastavnih tema: *Tipovi podataka (numerički, znakovni, liste); Algoritmi koji koriste različite tipove podataka*. Vidi prilog D.
- **Test mentalnog napora** u formi jednodimenzionalne Likertove ljestvice od 7 stupnjeva u svrhu subjektivne procjene uloženog mentalnog napora ispitanika za vrijeme učenja MIPL-a (Paas, F., 1992). Test za mjerenje mentalnog napora preuzet je od autora Leppink, J. i sur. (2013, str. 1070), preveden i prilagođen hrvatskom jeziku, te primijenjen nakon svakog tjedna istraživanja. Vidi prilog E.
- **Izlazni upitnik** u svrhu evaluacije metodičke i tehničke kvalitete multimedijskog sadržaja provedenog u eksperimentalnom programu te tehničkih

sastavnica MIPL-a. Izlazni upitnik primijenjen je jednom, nakon trećeg tjedna istraživanja odnosno na kraju eksperimentalnog programa. Vidi prilog F.

U istraživanju su korištena računala Učiteljskog fakulteta u Zagrebu i osobna prenosiva računala studenata (vlastiti izbor). Multimedijски sadržaj (MIPL) za provođenje eksperimentalnog programa pohranjen je na magnetski medij (CD) u obliku HTML verzije. Ispitanici su materijale pregledavali uz pomoć web-preglednika *Google Chrome*.

4.5.2 Varijable istraživanja

Temeljna nezavisna varijabla je obrazovni sadržaj za učenje Logo jezika prikazan putem multimedijске instruktivne poruke s primjenom, odnosno bez primjene načela raščlanjivanja. Zavisne varijable su količina zapamćenog sadržaja i razumijevanje sadržaja.

4.5.3 Plan istraživanja

Eksperimentalni program proveden je u trajanju od četiri tjedna (tablica 33) u zimskom semestru 2015./2016. akademske godine, što je obuhvaćalo inicijalni susret voditelja programa i ispitanika radi provođenja predtesta za dobivanje osnovnih informacija o ispitanicima, te tri tjedna istraživanja. U predtestu ispitanici su osmislili vlastite šifre radi kodiranja rezultata.

U prvom tjednu istraživanja ispitanici su prema abecednom redu dodijeljeni ili kontrolnoj ili eksperimentalnoj skupini. Prije početka istraživanja, voditelj eksperimentalnog programa detaljno je objasnio način provođenja istraživanja nakon čega su ispitanici imali 10 minuta vremena pregledati multimedijски sadržaj, zatim 15 minuta vremena za rješavanje odgovarajućih zadataka objektivnog tipa za provjeru znanja, te 5 minuta vremena za subjektivnu procjenu uloženog mentalnog napora kojeg su uložili za pregledavanje i upotrebu multimedijskog sadržaja. U trećem tjednu istraživanja ispitanici su ispunili upitnik za evaluaciju multimedijskog sadržaja eksperimentalnog programa. Sveukupni angažman studenata tijekom istraživanja iznosio je 160 minuta tijekom sva četiri tjedna istraživanja.

Svaki ispitanik je imao računalo na raspolaganju (fakultetsko ili vlastito), slušalice i CD medij s multimedijским sadržajem. Pri tome, imao je pravo koristiti multimedijски sadržaj kao pomoć u rješavanju zadataka. Nakon što su riješili zadatke, ispitanici su individualno predali CD i papire s riješenim zadacima voditelju programa. Ispitanici su zamoljeni da sadržaj

istraživanja ne dijele s drugima i tijekom provođenja trojednog programa ne proučavaju samostalno sadržaj koji se odnosi na eksperimentalni program.

Tablica 33. Plan istraživanja po tjednima

| Faza | Trajanje (minute) | Aktivnost | Opis |
|-------------------|-------------------|--|--|
| Inicijalni susret | 15 | Uvodna riječ voditelja eksperimentalnog programa | Predstavljanje i usmeno izlaganje plana istraživanja |
| | 15 | Dogovor oko načina izvođenja eksperimentalnog programa | Termini susreta i tehnička izvedba (računalna oprema) |
| | 10 | Predtest | Rod, mjesto (grad) studiranja, godina studija (dob ispitanika), općenito predznanje iz poznavanja programskih jezika, subjektivne procjene znanja iz programiranja i poznavanja osnovnih pojmova Logo jezika |
| Prvi tjedan | 5 | Podjela ispitanika u kontrolnu i eksperimentalnu skupinu | Podjela CD-a s multimedijским sadržajem za kontrolnu i eksperimentalnu skupinu |
| | 10 | Pregledavanje multimedijskog sadržaja (<i>Osnovne naredbe programskog jezika; Ponavljanje niza naredbi (REPEAT petlja); Uporaba petlje za crtanje niza likova</i>) | MIPL _{K1} |
| | | | MIPL _{E1} = KTMUZ načela (načelo raščlanjivanja (MIPL _{K1})) |
| | 15 | Rješavanje zadataka objektivnog tipa za provjeru znanja | Zapamćivanje sadržaja (3 zadatka) |
| | | | Razumijevanje sadržaja (2 zadatka) |
| | 5 | Ispunjavanje testa za mjerenje subjektivne procjene uloženog mentalnog napora | Likertova ljestvica od 7 stupnjeva (1 – premali mentalni napor; 7 – prejaki mentalni napor) |
| Drugi tjedan | 5 | Uvodna riječ voditelja eksperimentalnog programa | Sažeto ponavljanje pojmova od prethodnog tjedna |
| | 10 | Pregledavanje multimedijskog sadržaja | MIPL _{K2} |

| | | | |
|--------------|----|--|---|
| | | <i>(Ulazne vrijednosti procedura (MAKE naredba); Uporaba više ulaznih vrijednosti; Crtanje kocke i kvadra; Višestruke kornjače)</i> | MIPL _{E2} = KTMUZ načela (načelo raščlanjivanja (MIPL _{K2})) |
| | 15 | Rješavanje zadataka objektivnog tipa za provjeru znanja | Zapamćivanje sadržaja (4 zadatka) |
| | | | Razumijevanje sadržaja (2 zadatka) |
| | 5 | Ispunjavanje testa za mjerenje subjektivne procjene uloženog mentalnog napora | Likertova ljestvica od 7 stupnjeva (1 – premali mentalni napor; 7 – prejaki mentalni napor) |
| Treći tjedan | 5 | Uvodna riječ voditelja eksperimentalnog programa | |
| | 10 | Pregledavanje multimedijskog sadržaja <i>(Tipovi podataka (numerički, znakovni, liste); Algoritmi koji koriste različite tipove podataka)</i> | MIPL _{K3} |
| | | | MIPL _{E3} = KTMUZ načela (načelo raščlanjivanja (MIPL _{K3})) |
| | 15 | Rješavanje zadataka objektivnog tipa za provjeru znanja | Zapamćivanje sadržaja (3 zadatka) |
| | | | Razumijevanje sadržaja (3 zadatka) |
| | 5 | Ispunjavanje testa za mjerenje subjektivne procjene uloženog mentalnog napora | Likertova ljestvica od 7 stupnjeva (1 – premali mentalni napor; 7 – prejaki mentalni napor) |
| | 15 | Evaluacijski upitnik | Stupanj zanimljivosti, dosade, korisnosti i težine multimedijskog sadržaja provedenog u eksperimentalnog programu, te procjena kvalitete tehničkih sastavnica MIPL-a (tekst, grafika, govor, animacija) |

5 REZULTATI I DISKUSIJA

5.1 Analiza ispitanika

Istraživanje je provedeno na ciljanom uzorku 98 ispitanika studenata razredne nastave (III., IV. i V. godine studija), modula informatike, u Zagrebu (45) i Čakovcu (53). Od 45 ispitanika u Zagrebu njih 22 je abecednim redom dodijeljeno kontrolnoj skupini (MIPL bez primjene načela raščlanjivanja), a 23 eksperimentalnoj skupini (MIPL s primjenom načela raščlanjivanja). Od 53 ispitanika u Čakovcu njih 26 je abecednim redom dodijeljeno kontrolnoj skupini, a 27 eksperimentalnoj skupini. Sveukupno u kontrolnoj skupini bilo je 48 ispitanika, a u eksperimentalnoj 50 ispitanika.

Tablica 34. Prikaz strukture eksperimentalne i kontrolne skupine sa stajališta upotrebe programskog jezika na fakultetu

| Korištenje programskog jezika na fakultetu | Skupina | | | | Ukupno | |
|--|-----------------|-------|-----------|-------|--------|-------|
| | Eksperimentalna | | Kontrolna | | | |
| | N | % | N | % | N | % |
| Da | 31 | 62,0% | 25 | 52,1% | 56 | 57,1% |
| Ne | 19 | 38,0% | 23 | 47,9% | 42 | 42,9% |
| Ukupno | 50 | 100% | 48 | 100% | 98 | 100% |

Kako rezultati pokazuju (tablica 34) da postoji određeno odstupanje u broju ispitanika u eksperimentalnoj skupini obzirom na korištenje programskog jezika na fakultetu, distribucija ispitanika provjerena je hi-kvadrat testom. Rezultati analize pokazuju kako razdioba ispitanika po skupini ne odstupa statistički značajno od slučajnog rasporeda ($\chi^2=0,983$; $df=1$; $p=0,414$; $\phi=0,100$).

5.2 Ishodi učenja

Bloomova taksonomija, koju je razvio 1956. godine američki psiholog Benjamin Samuel Bloom i njegovi suradnici (Bloom, B. S. i sur., 1956; prema Krathwohl, D. R., 2002), jedna je od najpoznatijih i najprihvaćenijih klasifikacija ili taksonomija znanja za identificiranje različite razine postignuća, te određivanje ishoda učenja ili ciljeva poučavanja za određeno predmetno područje. Međutim, zbog teorijske orijentacije rada prema KTMUZ, u eksperimentalnom programu i interpretaciji rezultata koristila se podjela razine znanja prema

Mayeru (2001, 2005, 2014a), gdje zapamćivanje sadržaja MIPL-a (engl. *retention*) odgovara prvoj razini znanja (*zapamćivanje i usvajanje činjeničnog znanja*) obrazovnog ili kognitivnog područja, a razumijevanje sadržaja MIPL-a (engl. *transfer*) drugoj (*razumijevanje – sposobnost promišljanja o značenju usvojenih činjenica*) i trećoj (*primjena – sposobnost uporabe naučenih pravila u novim situacijama*) razini znanja kognitivnog područja Bloomove taksonomije razvoja pojedinca (Anderson, L. W. i sur., 2001, prema Krathwohl, D. R., 2002). Zapamćivanje sadržaja MIPL-a je sposobnost reproduciranja ili prepoznavanja prikazanog sadržaja čime se utvrđuje količina zapamćenog sadržaja. Mjeri se postignutim bodovima na zadacima objektivnog tipa (engl. *retention test*) prvog, drugog i trećeg tjedna istraživanja. Razumijevanje sadržaja MIPL-a je sposobnost primjene usvojenih činjenica u novim situacijama ili problemima čime se utvrđuje količina usvojenosti sadržaja. Mjeri se postignutim bodovima na zadacima objektivnog tipa (engl. *transfer test*) prvog, drugog i trećeg tjedna istraživanja, koji zahtijevaju rješavanje problema koji nisu eksplicitno prikazani u multimedijском sadržaju.

Svi zadatci objektivnog tipa utemeljeni su na hijerarhiji znanja u Logo jeziku, gdje se usvajanje znanja viših razina (strateško i shematično znanje) temelji na integraciji nižih razina (sintaktičko i semantičko znanje), (Fay, A. L. i Mayer, R. E., 1988; Mayer, R. E., 1992b, prema Lehrer, R., Lee, M., Jeong, A., 1999, str. 251-252). Zadatci su obuhvaćali prve tri razine znanja:

- (1) Sintaktičko (engl. *syntactic*) – znanje o osnovnim Logo naredbama i karakteristikama jezika. Mjeri se zadacima zapamćivanja sadržaja. Na primjer, prisjećanje, prepoznavanje i zapisivanje Logo naredbi.
- (2) Semantičko (engl. *semantic*) – znanje o mogućnostima primjene Logo naredbi. Mjeri se zadacima zapamćivanja sadržaja. Na primjer, primjena Logo naredbi za okretanje kornjače za određeni kut u odnosu na zadani početni položaj kornjače (engl. *move and turn mastery*), te razumijevanje koncepata varijabli, obrade listi i kontrole tijeka izvođenja programa (engl. *programming constructs*).
- (3) Shematično (engl. *schematic*) – znanje o zapisivanju Logo naredbi u složenije strukture radi izvršavanja specifičnih zadataka. Odnosi se na izgradnju veza između Logo naredbi ili programskih konstrukata. Mjeri se zadacima razumijevanja sadržaja. Na primjer, kod istovremenog prikaza tri Logo procedure ili niza procedura (engl. *procedure triads*) potrebno je odabrati dvije najsličnije i objasniti odabir, jer na površinskoj razini procedure mogu biti jednake po nazivu, ali na dubljoj različite po izvođenju (Lehrer, R., Lee, M., Jeong, A., 1999).

5.3 Predtest

Na početku eksperimentalnog programa u obje skupine (eksperimentalna i kontrolna) proveden je predtest koji je sadržavao osnovne informacije o ispitanicima. Predtestom su prikupljene sljedeće varijable (tablica 35):

- stupanj znanja programiranja,
- stupanj poznavanja osnovnih pojmova Logo jezika,
- subjektivna procjena znanja programiranja u Logo jeziku,
- stupanj zanimljivosti, dosade, korisnosti i težine programiranja općenito.

U svim je varijablama primijenjena Lickertova ljestvica od 5 stupnjeva.

Tablica 35. Analiza varijabli predtesta za cjelokupni uzorak ispitanika

| Rbr. | Varijabla | N | min | max | M | SD | C | Q1 | Q3 | Skew | Kurt | KS-z | p |
|------|--|----|-----|-----|------|-------|---|----|----|--------|--------|-------|-------|
| 1 | Procijenite svoje znanje programiranja (1 - nimalo, 5 - u potpunosti) | 98 | 1 | 4 | 1,76 | 0,733 | 2 | 1 | 2 | 0,581 | -0,353 | 0,257 | 0,000 |
| 2 | Koliko ste upoznati s osnovnim pojmovima Logo jezika (1 - nimalo, 5 - u potpunosti) | 98 | 1 | 5 | 1,61 | 0,808 | 1 | 1 | 2 | 1,425 | 2,404 | 0,327 | 0,000 |
| 3 | Procijenite svoje znanje programiranja u Logo jeziku | 98 | 1 | 4 | 1,44 | 0,719 | 1 | 1 | 2 | 1,664 | 2,340 | 0,403 | 0,000 |
| 4 | Programiranje mi je: Zanimljivo | 98 | 1 | 5 | 3,44 | 0,800 | 4 | 3 | 4 | -0,597 | 0,663 | 0,269 | 0,000 |
| 5 | Programiranje mi je: Dosadno | 98 | 1 | 4 | 2,31 | 0,709 | 2 | 2 | 3 | 0,187 | -0,068 | 0,300 | 0,000 |
| 6 | Programiranje mi je: Korisno | 98 | 2 | 5 | 4,06 | 0,655 | 4 | 4 | 4 | -0,512 | 0,978 | 0,320 | 0,000 |
| 7 | Programiranje mi je: Teško | 98 | 2 | 5 | 3,59 | 0,797 | 4 | 3 | 4 | -0,245 | -0,319 | 0,277 | 0,000 |

Prema KTMUZ stupanj učinkovitosti multimedijske poruke u unaprjeđenju zapamćivanja i razumijevanja sadržaja promatra se u odnosu na razinu predznanja i prostorne sposobnosti ispitanika (Mayer, R. E., 2001). Razina predznanja odnosi se na postojeće znanje iz određene

domene (engl *domain-specific knowledge*) koje ispitanik koristi u rješavanju problemskih situacija. Prostorna sposobnost se definira kao sposobnost stvaranja, održavanja i manipuliranja mentalnim vizualnim slikama (Carroll, J. B., 1993, prema Mayer, R. E. i Sims, V. K., 1994, str. 392), i predstavlja važan faktor u usvajanju znanja iz multimedijских prikaza odnosno prikaza koji su po svojoj prirodi verbalnog i vizualnog karaktera. Što se tiče razine predznanja ispitanika, iz tablice 35 je vidljivo kako je aritmetička sredina za varijable 1 ($M=1,76$), 2 ($M=1,61$) i 3 ($M=1,44$) iznimno niska uz relativno nisku i standardnu devijaciju što ukazuje da su studenti svoje znanje programiranja općenito, te poznavanje osnovnih pojmova Logo jezika i procjenu znanja programiranja u Logo jeziku procijenili niskim, iako se određeni broj njih susreo sa programskim jezikom Logo u osnovnoj školi. Također, ispitanici su se prvi put u sklopu fakultetskog obrazovanja susreli sa sadržajem prikazanim u istraživanju. Nadalje, pretpostavka je kako ispitanici posjeduju razvijene prostorne sposobnosti, jer se radi o studentima treće, četvrte i pete godine. Iz navedenih činjenica može se zaključiti kako ispitanici imaju nisko predznanje iz domene programiranja i bolje prostorne sposobnosti, što su poželjni čimbenici za uspješno provođenje eksperimentalnog programa, jer prema načelu individualnih razlika KTMUZ-a (Mayer, R. E., 2001) oni će imati više koristi od multimedijskog sadržaja nego ispitanici s visokom razinom predznanja i lošijom prostornom sposobnosti.

Što se tiče programiranja općenito, iz tablice 35 je vidljivo kako je razina dosade bavljenja programiranjem procijenjena vrlo niskom prosječnom ocjenom ($M=2,31$), stupanj zanimljivosti i težine relativno visokim prosječnim ocjenama ($M=3,44$; $M=3,59$), a korisnost visokom prosječnom ocjenom ($M=4,06$). Može se zaključiti kako ispitanici smatraju da malo znaju o programiranju općenito, da im ono nije dosadno, ali im je relativno teško, zanimljivo i korisno.

Radi provjere razlikovanja skupina u predtestu, provedene su analize razlika za svaku varijablu. Kako distribucije rezultata odstupaju od normalnih, za analizu razlika korišten je Mann-Whitneyev test kao neparametrijska alternativa t-testu. Rezultati ovog testa prikazani su u tablici 36.

Tablica 36. Prikaz statističke značajnosti razlika između eksperimentalne i kontrolne skupine prema varijablama za cjelokupni uzorak ispitanika

| Varijabla | Skupina | N | Pros. rang | MWU | p |
|--|-----------------|----|---------------|----------|------|
| Procijenite svoje znanje programiranja | Eksperimentalna | 50 | 49,54 | 1198,000 | ,988 |
| | Kontrolna | 48 | 49,46 | | |
| Koliko ste upoznati s osnovnim pojmovima Logo jezika | Eksperimentalna | 50 | 47,87 | 1118,500 | ,517 |
| | Kontrolna | 48 | 51,20 | | |
| Procijenite svoje znanje programiranja u Logo jeziku | Eksperimentalna | 50 | 45,97 | 1023,500 | ,129 |
| | Kontrolna | 48 | 53,18 | | |
| Programiranje mi je: Zanimljivo | Eksperimentalna | 50 | 50,68 | 1141,000 | ,648 |
| | Kontrolna | 48 | 48,27 | | |
| Programiranje mi je: Dosadno | Eksperimentalna | 50 | 47,78 | 1114,000 | ,498 |
| | Kontrolna | 48 | 51,29 | | |
| Programiranje mi je: Korisno | Eksperimentalna | 50 | 48,82 | 1166,000 | ,778 |
| | Kontrolna | 48 | 50,21 | | |
| Programiranje mi je: Teško | Eksperimentalna | 50 | 49,91 | 1179,500 | ,875 |
| | Kontrolna | 48 | 49,07 | | |

Rezultati analiza pokazuju da nema statistički značajnih razlika među ispitanicima kontrolne i eksperimentalne skupine u pogledu varijabli u predtestu (stupanj znanja programiranja, stupanj poznavanja osnovnih pojmova Logo jezika, subjektivna procjena znanja programiranja u Logo jeziku, stupanj zanimljivosti, dosade, korisnosti i težine programiranja općenito). To pokazuje kako su eksperimentalna i kontrolna skupina u pogledu varijabli predtesta dobro uravnotežene, što je iznimno važno za provođenje eksperimentalnog programa i interpretaciju rezultata.

5.4 Analiza rezultata provedenog testiranja za prvi tjedan eksperimentalnog programa

5.4.1 Deskriptivni podatci

U prvom tjednu eksperimentalnog programa ispitanici su nakon podjele na eksperimentalnu (MIPL_{E1}) i kontrolnu (MIPL_{K1}) skupinu pregledali multimedijски sadržaj iz nastavnih tema (10 minuta): *Osnovne naredbe programskog jezika; Ponavljanje niza naredbi (REPEAT petlja); Uporaba petlje za crtanje niza likova*. Zatim su rješavali odgovarajuće zadatke objektivnog tipa za provjeru znanja (15 minuta): 3 zadatka za mjerenje zapamćivanja sadržaja i 2 zadatka za mjerenje razumijevanja sadržaja. Nakon što su riješili zadatke ispunili su upitnik za subjektivnu procjenu uloženog mentalnog napora koji su uložili na pregledavanje i upotrebu multimedijskog sadržaja (5 minuta).

U tablici 37 prikazani su deskriptivni podatci za zadatke u prvom tjednu istraživanja.

Tablica 37. Prikaz rezultata u prvom tjednu istraživanja za obje skupine (eksperimentalna i kontrolna)

| Zadatak | Skupina | Deskriptivna statistika | | | | | | | | % ispitanika po broju ostvarenih bodova | | | | | | |
|--|-----------------|-------------------------|------------------|------|-------|-----|-----|-----|------|---|-------|-------|-------|------|-------|------|
| | | N | MAX _t | M | SD | C | Q1 | Q3 | p | ,0 | ,5 | 1,0 | 2,0 | 2,5 | 3,0 | 4,0 |
| I. Tjedan (Zapamćivanje) 1 zadatak | Eksperimentalna | 50 | 4 | 2,22 | 1,093 | 3,0 | 2,0 | 3,0 | 0,56 | 16,0% | 0,0% | 2,0% | 26,0% | 0,0% | 56,0% | 0,0% |
| | Kontrolna | 48 | 4 | 2,69 | ,803 | 3,0 | 3,0 | 3,0 | 0,67 | 6,3% | 0,0% | 0,0% | 14,6% | 0,0% | 77,1% | 2,1% |
| | Ukupno | 98 | 4 | 2,45 | ,986 | 3,0 | 2,0 | 3,0 | 0,61 | 11,2% | 0,0% | 1,0% | 20,4% | 0,0% | 66,3% | 1,0% |
| I. Tjedan (Zapamćivanje) 2 zadatak | Eksperimentalna | 50 | 1 | ,28 | ,406 | 0,0 | 0,0 | ,5 | 0,28 | 64,0% | 16,0% | 20,0% | | | | |
| | Kontrolna | 48 | 1 | ,19 | ,336 | 0,0 | 0,0 | ,5 | 0,19 | 72,9% | 16,7% | 10,4% | | | | |
| | Ukupno | 98 | 1 | ,23 | ,374 | 0,0 | 0,0 | ,5 | 0,23 | 68,4% | 16,3% | 15,3% | | | | |
| I. Tjedan (Zapamćivanje) 3 zadatak | Eksperimentalna | 50 | 2 | 1,06 | ,998 | 2,0 | 0,0 | 2,0 | 0,53 | 46,0% | 0,0% | 2,0% | 52,0% | | | |
| | Kontrolna | 48 | 2 | 1,08 | ,964 | 1,5 | 0,0 | 2,0 | 0,54 | 41,7% | 0,0% | 8,3% | 50,0% | | | |
| | Ukupno | 98 | 2 | 1,07 | ,977 | 2,0 | 0,0 | 2,0 | 0,54 | 43,9% | 0,0% | 5,1% | 51,0% | | | |

| | | | | | | | | | | | | | | | | |
|-------------------|-----------------|----|---|------|------|-----|-----|-----|------|-------|------|-------|------|------|-------|-------|
| I. Tjedan | Eksperimentalna | 50 | 4 | 3,01 | ,799 | 3,0 | 3,0 | 3,0 | 0,75 | 4,0% | 0,0% | 0,0% | 6,0% | 2,0% | 68,0% | 20,0% |
| (Razumijevanje) 4 | Kontrolna | 48 | 4 | 3,06 | ,633 | 3,0 | 3,0 | 3,0 | 0,77 | 2,1% | 0,0% | 0,0% | 4,2% | 0,0% | 77,1% | 16,7% |
| zadatak | Ukupno | 98 | 4 | 3,04 | ,719 | 3,0 | 3,0 | 3,0 | 0,76 | 3,1% | 0,0% | 0,0% | 5,1% | 1,0% | 72,4% | 18,4% |
| I. Tjedan | Eksperimentalna | 50 | 1 | ,39 | ,487 | 0,0 | 0,0 | 1,0 | 0,39 | 60,0% | 2,0% | 38,0% | | | | |
| (Razumijevanje) 5 | Kontrolna | 48 | 1 | ,59 | ,480 | 1,0 | 0,0 | 1,0 | 0,59 | 37,5% | 6,3% | 56,3% | | | | |
| zadatak | Ukupno | 98 | 1 | ,49 | ,492 | ,5 | 0,0 | 1,0 | 0,49 | 49,0% | 4,1% | 46,9% | | | | |

MAXt – teorijski maksimalni broj bodova

M – aritmetička sredina

SD – standardna devijacija

C – medijan

Q1 – rezultat na prvom kvartilu

Q3 – rezultat na trećem kvartilu

p – indeks lakoće zadatka (računa se kao omjer aritmetičke sredine i teorijskog maksimalnog broja bodova u zadatku)

Prvi u nizu zadataka objektivnog tipa mjerio je sintaktičku i semantičku razinu znanja u Logo jeziku – poznavanje osnovnih naredbi FD i BK (naredbe za pomicanje grafičkog pokazivača kornjače naprijed i natrag za zadani parametar u odnosu na početni položaj kornjače). Teorijski maksimalni broj bodova na ovom zadatku bio je 4. Kontrolna skupina se pokazala uspješnijom od eksperimentalne. U kontrolnoj skupini srednja vrijednost ostvarenih bodova iznosila je 2,69, a standardna devijacija 0,803, dok je u eksperimentalnoj skupini srednja vrijednost ostvarenih bodova iznosila 2,22, sa znatno višom standardnom devijacijom (SD=1,093). Zanimljivo je da je jedino 2,1% ispitanika kontrolne skupine ostvarilo maksimalni broj bodova, dok u eksperimentalnoj skupini to nije uspjelo niti jednom ispitaniku. Tri boda u kontrolnoj skupini ostvarilo je 77,1% ispitanika, a u eksperimentalnoj 56% ispitanika.

Drugi u nizu zadataka objektivnog tipa mjerio je sintaktičku i semantičku razinu znanja u Logo jeziku – poznavanje osnovnih naredbi FD i BK, poznavanje osnovnih naredbi RT i LT (naredbe za okretanje kornjače udesno i ulijevo za zadani parametar u odnosu na početni položaj kornjače), te vještine konkretnog praćenja izvođenja programa (engl. *code-tracing*), (zadane vrijednosti parametara naredbi, pomaci = 50, 100; kut rotacije = 120) i čitanja programa (engl. *code-reading*). Teorijski maksimalni broj bodova na ovom zadatku bio je 1. Eksperimentalna skupina se pokazala uspješnijom od kontrolne. U eksperimentalnoj skupini srednja vrijednost ostvarenih bodova iznosila je 0,28 (SD=0,406), a u kontrolnoj skupini srednja vrijednost ostvarenih bodova iznosila je 0,19 (SD=0,336). 20% ispitanika u eksperimentalnoj skupini je ostvarilo maksimalni broj bodova, dok je u kontrolnoj skupini to ostvarilo 10,4% ispitanika.

Treći u nizu zadataka objektivnog tipa mjerio je sintaktičku i semantičku razinu znanja u Logo jeziku – poznavanje osnovnih naredbi PU i PD (naredbe za podizanje i spuštanje grafičkog pokazivača kornjače), te vještine konkretnog praćenja izvođenja programa (zadane vrijednosti parametara naredbi, broj ponavljanja REPEAT petlje = 3; pomak = 40; kut rotacije = 120) i čitanja programa. Teorijski maksimalni broj bodova na ovom zadatku bio je 2. Eksperimentalna i kontrolna skupina postigle su podjednake rezultate, gdje je u eksperimentalnoj skupini 52% ispitanika ostvarilo maksimalni broj bodova, dok je u kontrolnoj skupini to ostvarilo 50% ispitanika.

Četvrti i peti zadatci objektivnog tipa mjerili su shematičnu razinu znanja u Logo jeziku – razumijevanje osnovnih naredbi (FD, BK, RT, LT, PU, PD), te vještinu pisanja programa (engl. *code-writing*), (upotreba programske strukture REPEAT petlje). U četvrtom zadatku eksperimentalna i kontrolna skupina postigle su podjednake rezultate, gdje je u eksperimentalnoj skupini 20% ispitanika ostvarilo maksimalni broj bodova, dok je u kontrolnoj skupini to ostvarilo 16,7% ispitanika. U petom zadatku maksimalni broj bodova u kontrolnoj skupini ostvarilo je 56,3% ispitanika, dok je u eksperimentalnoj skupini to ostvarilo samo 38,0% ispitanika. Kontrolna skupina pokazala je malo bolji uspjeh u rješavanju zadatka.

Ukupan rezultat niza zadataka objektivnog tipa formiran je kao suma bodova na pojedinim zadatcima. Radi kasnijih analiza formirana su tri ukupna rezultata: rezultat za zadatke koji mjere zapamćivanje sadržaja (7 bodova), rezultat za zadatke koji mjere razumijevanje sadržaja (5 bodova) i rezultat za sve zadatke (12 bodova). Deskriptivni pokazatelji za niz zadataka objektivnog tipa prikazani su u tablici 38.

Tablica 38. Prikaz ukupnih rezultata eksperimentalne i kontrolne skupine za zadatke zapamćivanja i razumijevanja sadržaja za I. tjedan istraživanja

| Varijabla | Skupina | N | min | max | M | SD | C | Q1 | Q3 | Skew | Kurt | KS-z | p |
|-----------------------------------|-----------------|----|-----|-----|------|-------|------|----|----|--------|--------|-------|-------|
| 1. tjedan – Zadatci zapamćivanja | Eksperimentalna | 50 | 0 | 6 | 3,56 | 1,769 | 3,25 | 2 | 5 | -0,417 | -0,690 | 0,192 | 0,000 |
| | Kontrolna | 48 | 0 | 7 | 3,96 | 1,480 | 4,00 | 3 | 5 | -0,866 | 1,479 | 0,175 | 0,001 |
| | Ukupno | 98 | 0 | 7 | 3,76 | 1,638 | 4,00 | 3 | 5 | -0,628 | 0,006 | 0,164 | 0,000 |
| 1. tjedan – Zadatci razumijevanja | Eksperimentalna | 50 | 0 | 5 | 3,40 | 1,064 | 3,00 | 3 | 4 | -0,891 | 2,731 | 0,274 | 0,000 |
| | Kontrolna | 48 | 1 | 5 | 3,66 | 0,826 | 4,00 | 3 | 4 | -0,644 | 1,329 | 0,245 | 0,000 |
| | Ukupno | 98 | 0 | 5 | 3,53 | 0,959 | 3,50 | 3 | 4 | -0,898 | 2,641 | 0,220 | 0,000 |
| 1. tjedan – UKUPNO | Eksperimentalna | 50 | 0 | 11 | 6,96 | 2,539 | 7,00 | 5 | 9 | -0,649 | 0,598 | 0,120 | 0,069 |
| | Kontrolna | 48 | 3 | 12 | 7,61 | 1,883 | 7,50 | 6 | 9 | -0,403 | 0,298 | 0,165 | 0,002 |
| | Ukupno | 98 | 0 | 12 | 7,28 | 2,255 | 7,25 | 6 | 9 | -0,696 | 0,911 | 0,124 | 0,001 |

min,max – najniži i najviši ostvareni rezultat

M – aritmetička sredina

SD – standardna devijacija

C – medijan

Q1 – rezultat na prvom kvartilu

Q3 – rezultat na trećem kvartilu

Skew – Asimetrija (engl. Skewness) distribucije

Kurt – Spljoštenost (Kurtozija, engl. Kurtosis)

KS-z – Kolmogorov Smirnovljev test normaliteta distribucije

p – Statistička značajnost KS testa (ako je $p < 0,05$ distribucija nije normalna)

Prvi zadatak provjeravao je kognitivno prepoznavanje učinka pojedinačne naredbe na pomake i rotaciju grafičkog pokazivača kornjače. Rezultati su pokazali kako primijenjeno načelo raščlanjivanja u formi animacije linearnog kretanja kornjače prema naprijed i natrag, te animacije rotacije kornjače udesno i ulijevo nije značajno pridonijelo razumijevanju osnovnih naredbi: FD, BK, RT, LT. Drugi i treći zadatak predstavljali su nadogradnju prvog zadatka i dodatno provjeravali sposobnost praćenja izvođenja i čitanja (objašnjavanja) programskog kôda prema zadanoj listi naredbi. Rezultati su pokazali nedovoljnu razinu geometrijskog predznanja ispitanika u poznavanju kutova, zbog neuspješne vizualizacije putanje kretanja kornjače prema zadanim parametrima naredbi, što je otežalo praćenje izvođenja i čitanja programa. Četvrti i peti zadatak provjeravali su vještinu pisanja programa upotrebom osnovnih naredbi i programske strukture REPEAT petlje prema zadanim slikovnim prikazima geometrijskih likova. Općenito, vještina pisanja programa ovisi o znanju osnovnih programskih koncepata (naredbe, petlje) i vještinama praćenja izvođenja i čitanja programa (Lister, R. i sur., 2006; Lopez, M. i sur., 2008; Lister, R., Fidge, C. i Teague, D., 2009; Venables, A., Tan, G. i Lister, R., 2009; Clear, T. i sur., 2011; Sorva, J., 2012; Corney, M. i sur., 2014). Međutim, u ovom slučaju nedostatak geometrijskog predznanja otežao je proces usvajanja osnovnih naredbi, a samim time i pisanje programa u posljednjim dvama zadacima.

5.4.2 Testiranje razlika između eksperimentalne i kontrolne skupine

S obzirom na deskriptivne pokazatelje koji su ukazali da ne postoji statistička normalnost distribucija, za analizu razlika korištena je neparametrijska statistika, odnosno u ovom slučaju Mann-Whitneyev test. Rezultati analiza prikazani su u tablici 39.

Tablica 39. Testiranje razlika između eksperimentalne i kontrolne skupine u pogledu zapamćivanja i razumijevanja sadržaja

| Varijabla | Skupina | N | Pros. rang | U | p | r |
|------------------------------|-----------------|----|---------------|--------|-------|-------|
| 1. tjedan – Zapamćivanje | Eksperimentalna | 50 | 46,32 | 1041 | 0,252 | 0,116 |
| | Kontrolna | 48 | 52,81 | | | |
| 1. tjedan – Razumijevanje | Eksperimentalna | 50 | 45,34 | 992 | 0,118 | 0,158 |
| | Kontrolna | 48 | 53,83 | | | |
| 1. tjedan – UKUPNO | Eksperimentalna | 50 | 45,69 | 1009,5 | 0,172 | 0,138 |
| | Kontrolna | 48 | 53,47 | | | |

U – rezultat Mann-Whitney testa

p – statistička značajnost

r – koeficijent veličine efekta (računa se iz rezultata Mann-Whitneyevog testa po formuli $r = \frac{z}{\sqrt{N}}$ (Rosenthal, R., 1991).

Rezultati provedenih analiza pokazuju kako u svim analizama nije dobivena statistički značajna razlika u broju ostvarenih bodova na zadacima objektivnog tipa. Uvidom u veličine efekata pokazuje se da se radi o niskim efektima. Sve dosadašnje razlike koje su se pojavljivale između eksperimentalne i kontrolne skupine pokazale su se statistički beznačajnim.

5.4.3 Testiranje razlika po godinama studija

Za analizu razlika po godinama studija korišten je Kruskal-Wallisov test kao neparametrijska alternativa analizi varijance s Mann-Whitneyevim testom za post hoc testiranje razlika među pojedinim skupinama. Kako neparametrijska statistika ne omogućuje složene faktorijske nacrt, analize su provedene zasebno za svaku skupinu i ukupno. Rezultati analiza prikazani su u tablici 40.

Tablica 40. Rezultati testiranja razlika po pripadnosti studijskoj godini

| Varijabla | Skupina | Godina | N | Medijan | Prosj. rang | X ² |
|---------------------------|-----------------|--------|----|---------|-------------|----------------|
| 1. tjedan – Zapamćivanje | Eksperimentalna | 3 | 14 | 4 | 29,25 | 1,334 |
| | | 4 | 16 | 3 | 23,72 | |
| | | 5 | 20 | 3,25 | 24,30 | |
| | Kontrolna | 3 | 14 | 4 | 24,64 | 1,951 |
| | | 4 | 15 | 3 | 20,73 | |
| | | 5 | 19 | 4 | 27,37 | |
| | Ukupno | 3 | 28 | 4 | 52,80 | 1,257 |
| | | 4 | 31 | 3 | 45,00 | |
| | | 5 | 39 | 4 | 50,71 | |
| 1. tjedan – Razumijevanje | Eksperimentalna | 3 | 14 | 3 | 24,14 | 0,205 |
| | | 4 | 16 | 3 | 25,78 | |
| | | 5 | 20 | 3 | 26,23 | |
| | Kontrolna | 3 | 14 | 4 | 27,50 | 1,135 |
| | | 4 | 15 | 4 | 24,07 | |
| | | 5 | 19 | 3,5 | 22,63 | |
| | Ukupno | 3 | 28 | 4 | 50,66 | 0,108 |
| | | 4 | 31 | 3,5 | 49,71 | |
| | | 5 | 39 | 3 | 48,50 | |
| 1. tjedan – UKUPNO | Eksperimentalna | 3 | 14 | 7,5 | 27,68 | 0,449 |
| | | 4 | 16 | 6,25 | 24,41 | |
| | | 5 | 20 | 6,5 | 24,85 | |
| | Kontrolna | 3 | 14 | 8 | 26,68 | 1,005 |
| | | 4 | 15 | 7 | 21,70 | |
| | | 5 | 19 | 8 | 25,11 | |
| | Ukupno | 3 | 28 | 8 | 52,71 | 0,81 |
| | | 4 | 31 | 7 | 46,15 | |
| | | 5 | 39 | 7 | 49,86 | |

X² – rezultat Kruskal-Wallis testa

* p<0,05

Rezultati provedenih analiza pokazuju da niti u jednoj usporedbi nisu dobivene statistički značajne razlike.

5.5 Analiza rezultata provedenog testiranja za drugi tjedan eksperimentalnog programa

5.5.1 Deskriptivni podatci

U drugom tjednu eksperimentalnog programa ispitanici su pregledali multimedijски sadržaj iz nastavnih tema (10 minuta): *Ulazne vrijednosti procedura (MAKE naredba); Uporaba više ulaznih vrijednosti; Crtanje kocke i kvadra; Višestruke kornjače*. Zatim su rješavali odgovarajuće zadatke objektivnog tipa za provjeru znanja (15 minuta): 4 zadatka za mjerenje zapamćivanja sadržaja i 2 zadatka za mjerenje razumijevanja sadržaja. Nakon što su riješili zadatke ispunili su upitnik za subjektivnu procjenu uloženog mentalnog napora koji su uložili na pregledavanje i upotrebu multimedijskog sadržaja (5 minuta).

U tablici 41 prikazani su deskriptivni podatci za zadatke u drugom tjednu istraživanja.

Tablica 41. Prikaz rezultata u drugom tjednu istraživanja za obje skupine (eksperimentalna i kontrolna)

| Zadatak | Skupina | Deskriptivna statistika | | | | | | | | % ispitanika po broju ostvarenih bodova | | | | | |
|--|-----------------|-------------------------|------------------|-----|------|-----|-----|-----|-----|---|-------|-------|-----|-----|-----|
| | | N | MAX _t | M | SD | C | Q1 | Q3 | p | ,0 | 0-1 | 1,0 | 2,0 | 3,0 | 4,0 |
| II. Tjedan (Zapamćivanje) 1a zadatak | Eksperimentalna | 50 | 1 | ,94 | ,240 | 1,0 | 1,0 | 1,0 | ,94 | 6,0% | 0,0% | 94,0% | | | |
| | Kontrolna | 48 | 1 | ,96 | ,202 | 1,0 | 1,0 | 1,0 | ,96 | 4,2% | 0,0% | 95,8% | | | |
| | Ukupno | 98 | 1 | ,95 | ,221 | 1,0 | 1,0 | 1,0 | ,95 | 5,1% | 0,0% | 94,9% | | | |
| II. Tjedan (Zapamćivanje) 1b zadatak | Eksperimentalna | 50 | 1 | ,88 | ,328 | 1,0 | 1,0 | 1,0 | ,88 | 12,0% | 0,0% | 88,0% | | | |
| | Kontrolna | 48 | 1 | ,90 | ,309 | 1,0 | 1,0 | 1,0 | ,90 | 10,4% | 0,0% | 89,6% | | | |
| | Ukupno | 98 | 1 | ,89 | ,317 | 1,0 | 1,0 | 1,0 | ,89 | 11,2% | 0,0% | 88,8% | | | |
| II. Tjedan (Zapamćivanje) 2 zadatak | Eksperimentalna | 50 | 1 | ,24 | ,342 | 0,0 | 0,0 | ,5 | ,24 | 62,0% | 32,0% | 6,0% | | | |
| | Kontrolna | 48 | 1 | ,31 | ,352 | ,3 | 0,0 | ,5 | ,31 | 45,8% | 43,8% | 10,4% | | | |
| | Ukupno | 98 | 1 | ,28 | ,347 | 0,0 | 0,0 | ,5 | ,28 | 54,1% | 37,8% | 8,2% | | | |

| | | | | | | | | | | | | | | | |
|--|-----------------|----|---|------|------|-----|-----|-----|-----|-------|-------|-------|------|------|-------|
| II. Tjedan (Razumijevanje) 3 zadatak | Eksperimentalna | 50 | 1 | ,56 | ,451 | ,8 | 0,0 | 1,0 | ,56 | 36,0% | 22,0% | 42,0% | | | |
| | Kontrolna | 48 | 1 | ,61 | ,437 | ,8 | 0,0 | 1,0 | ,61 | 31,3% | 25,0% | 43,8% | | | |
| | Ukupno | 98 | 1 | ,59 | ,443 | ,8 | 0,0 | 1,0 | ,59 | 33,7% | 23,5% | 42,9% | | | |
| II. Tjedan (Zapamćivanje) 4 zadatak | Eksperimentalna | 50 | 4 | 3,74 | ,876 | 4,0 | 4,0 | 4,0 | ,94 | 4,0% | 0,0% | 0,0% | 4,0% | 2,0% | 90,0% |
| | Kontrolna | 48 | 4 | 3,94 | ,320 | 4,0 | 4,0 | 4,0 | ,98 | 0,0% | 0,0% | 0,0% | 2,1% | 2,1% | 95,8% |
| | Ukupno | 98 | 4 | 3,84 | ,669 | 4,0 | 4,0 | 4,0 | ,96 | 2,0% | 0,0% | 0,0% | 3,1% | 2,0% | 92,9% |
| II. Tjedan (Razumijevanje) 5 zad. | Eksperimentalna | 50 | 1 | ,23 | ,377 | 0,0 | 0,0 | ,6 | ,23 | 70,0% | 24,0% | 6,0% | | | |
| | Kontrolna | 48 | 1 | ,21 | ,328 | 0,0 | 0,0 | ,5 | ,21 | 68,8% | 31,3% | 0,0% | | | |
| | Ukupno | 98 | 1 | ,22 | ,352 | 0,0 | 0,0 | ,5 | ,22 | 69,4% | 26,5% | 3,1% | | | |

MAXt – teorijski maksimalni broj bodova

M – aritmetička sredina

SD – standardna devijacija

C – medijan

Q1 – rezultat na prvom kvartilu

Q3 – rezultat na trećem kvartilu

p – indeks lakoće zadatka (računa se kao omjer aritmetičke sredine i teorijskog maksimalnog broja bodova u zadatku)

Prvi, drugi i četvrti zadatak provjeravali su zapamćivanje sadržaja, a treći i peti zadatak razumijevanje sadržaja MIPL-a.

Prvi u nizu zadataka objektivnog tipa mjerio je sintaktičku i semantičku razinu znanja u Logo jeziku – poznavanje osnovnih naredbi (FD, RT, LT), rad procedure s nepromjenjivim vrijednostima, te vještine konkretnog praćenja izvođenja procedure (engl. *code-tracing*), (zadane vrijednosti parametara naredbi, pomak = 40; kut rotacije = 120) i čitanja procedure (engl. *code-reading*). Teorijski maksimalni broj bodova na prvom dijelu (1a) i drugom dijelu zadatka (1b) bio je sveukupno 2. Kontrolna i eksperimentalna skupina postigle su podjednake rezultate. U

kontrolnoj skupini srednja vrijednost ostvarenih bodova za 1a zadatak iznosila je 0,96 (SD=0,202), a za 1b zadatak 0,90 (SD=0,309). U eksperimentalnoj skupini za 1a zadatak srednja vrijednost ostvarenih bodova iznosila je 0,94 boda (SD=0,240), a za 1b zadatak 0,88 (SD=0,328).

Drugi u nizu zadataka objektivnog tipa mjerio je sintaktičku i semantičku razinu znanja u Logo jeziku – poznavanje osnovnih naredbi (FD, RT, LT), rad procedure s promjenjivim ulaznim vrijednostima (varijable: A, B, KUT), te vještine konkretnog praćenja izvođenja procedure (zadane vrijednosti parametara naredbi, A = 50, B = 20, KUT = 30) i čitanja procedure. Teorijski maksimalni broj bodova na ovom zadatku bio je 1. Kontrolna skupina pokazala je malo bolji uspjeh u rješavanju zadatka. U eksperimentalnoj skupini srednja vrijednost ostvarenih bodova iznosila je 0,24 (SD=0,342), a u kontrolnoj skupini 0,31 (SD=0,352). 6% ispitanika u eksperimentalnoj skupini je ostvarilo maksimalni broj bodova, dok je u kontrolnoj skupini to ostvarilo 10,4% ispitanika.

Četvrti u nizu zadataka objektivnog tipa mjerio je sintaktičku i semantičku razinu znanja u Logo jeziku – poznavanje osnovnih naredbi za rad s više kornjača (SETTURTLES, TELL, ASK), rad procedure s nepromjenjivim vrijednostima, te vještine konkretnog praćenja izvođenja procedure (zadane vrijednosti parametara naredbi, broj kornjača = 4; pomaci = 30, 50; kut rotacije = 60) i čitanja procedure. Teorijski maksimalni broj bodova na ovom zadatku bio je 4. Kontrolna i eksperimentalna skupina postigle su podjednake rezultate. U kontrolnoj skupini srednja vrijednost ostvarenih bodova iznosila je 3,94 (SD=0,320), a u eksperimentalnoj skupini 3,74 (SD=0,876).

Treći u nizu zadataka objektivnog tipa mjerio je shematičnu razinu znanja u Logo jeziku – razumijevanje osnovnih naredbi (FD, BK, RT, LT, PU, PD), upotrebu programske strukture REPEAT petlje, te vještinu pisanja procedure (engl. *code-writing*) s promjenjivim ulaznim vrijednostima (varijabla A). Teorijski maksimalni broj bodova na ovom zadatku bio je 1. Kontrolna i eksperimentalna skupina postigle su podjednake rezultate, gdje je maksimalni broj bodova u kontrolnoj skupini ostvarilo 43,8% ispitanika, a u eksperimentalnoj 42% ispitanika, što je relativno niska rješivost zadatka.

Peti u nizu zadataka objektivnog tipa mjerio je shematičnu razinu znanja u Logo jeziku – razumijevanje osnovnih naredbi (FD, BK, RT, LT, PU, PD), naredbi za rad s više kornjača (SETTURTLES, TELL, ASK), upotrebu gotovih procedura s promjenjivim ulaznim vrijednostima (crtanje paralelograma s duljinama stranica A i B), te vještinu pisanja procedure. Teorijski maksimalni broj bodova na ovom zadatku bio je 1. Kontrolna (M=0,21; SD=0,328) i eksperimentalna (M=0,23; SD=0,377) skupina postigle su podjednake rezultate, gdje je maksimalni broj bodova u eksperimentalnoj skupini ostvarilo 6% ispitanika, a u kontrolnoj niti jedan ispitanik (0%).

Ukupan rezultat niza zadataka objektivnog tipa formiran je kao suma bodova na pojedinim zadacima. Radi kasnijih analiza formirana su tri ukupna rezultata: rezultat za zadatke koji mjere zapamćivanje sadržaja (7 bodova), rezultat za zadatke koji mjere razumijevanje sadržaja (2 boda) i rezultat za sve zadatke (9 bodova). Deskriptivni pokazatelji za niz zadataka objektivnog tipa prikazani su u tablici 42.

Tablica 42. Prikaz ukupnih rezultata eksperimentalne i kontrolne skupine za zadatke zapamćivanja i razumijevanja sadržaja za II. tjedan istraživanja

| Varijabla | Skupina | N | min | max | M | SD | C | Q1 | Q3 | Skew | Kurt | KS-z | p |
|-----------------------------------|-----------------|----|-----|------|------|-------|-----|-----|-----|--------|--------|-------|-------|
| 2. tjedan – Zadatci zapamćivanja | Eksperimentalna | 50 | 2 | 7 | 5,80 | 1,135 | 6,0 | 6,0 | 6,5 | -1,974 | 4,041 | 0,350 | 0,000 |
| | Kontrolna | 48 | 4 | 7 | 6,10 | 0,652 | 6,0 | 6,0 | 6,5 | -0,968 | 1,150 | 0,249 | 0,000 |
| | Ukupno | 98 | 2 | 7 | 5,95 | 0,938 | 6,0 | 6,0 | 6,5 | -2,126 | 5,934 | 0,318 | 0,000 |
| 2. tjedan – Zadatci razumijevanja | Eksperimentalna | 50 | 0 | 2 | 0,79 | 0,645 | 1,0 | 0,0 | 1,1 | 0,196 | -1,007 | 0,191 | 0,000 |
| | Kontrolna | 48 | 0 | 1,91 | 0,82 | 0,634 | 1,0 | 0,0 | 1,2 | 0,011 | -1,100 | 0,195 | 0,000 |
| | Ukupno | 98 | 0 | 2 | 0,81 | 0,637 | 1,0 | 0,0 | 1,2 | 0,105 | -1,067 | 0,194 | 0,000 |
| 2. tjedan – UKUPNO | Eksperimentalna | 50 | 2 | 8,75 | 6,59 | 1,448 | 6,8 | 6,0 | 7,5 | -1,348 | 2,695 | 0,181 | 0,000 |
| | Kontrolna | 48 | 4 | 8,91 | 6,93 | 1,051 | 7,0 | 6,1 | 7,8 | -0,658 | 0,231 | 0,131 | 0,037 |
| | Ukupno | 98 | 2 | 8,91 | 6,76 | 1,274 | 7,0 | 6,0 | 7,7 | -1,277 | 2,836 | 0,133 | 0,000 |

min,max – najniži i najviši ostvareni rezultat

M – aritmetička sredina

SD – standardna devijacija

C – medijan

Q1 – rezultat na prvom kvartilu

Q3 – rezultat na trećem kvartilu

Skew – Asimetrija (engl. Skewness) distribucije

Kurt – Spljoštenost (Kurtozija, engl. Kurtosis)

KS-z – Kolmogorov Smirnovljev test normaliteta distribucije

p – Statistička značajnost KS testa (ako je $p < 0,05$ distribucija nije normalna)

Iz tablice 42 je vidljivo da nisu nađene statistički značajne razlike između kontrolne i eksperimentalne skupine u pogledu rješavanja zadataka zapamćivanja i razumijevanja sadržaja za II. tjedan istraživanja.

Prvi, drugi i četvrti zadatak provjeravali su kognitivno prepoznavanje učinka pojedinačne naredbe na pomake i rotaciju grafičkog pokazivača kornjače, te vještine konkretnog praćenja izvođenja procedura (zadane vrijednosti parametara naredbi) i čitanja procedure. Rezultati prvog i četvrtog zadatka su pokazali relativno visoku rješivost zadataka. Rezultati drugog zadatka su pokazali kako ispitanici nemaju dovoljno geometrijskog predznanja u poznavanju kutova, likova (paralelogram, romb) i ploha (kocka), što je otežalo praćenje izvođenja i čitanja procedure, jer nisu bili uspješni u označavanju vrijednosti unutarnjih kutova i duljina stranica na crtežu paralelograma niti u vizualizaciji putanje kretanja kornjače prema zadanim parametrima naredbi. Zbog nedovoljne razine geometrijskog predznanja nije bilo moguće adekvatno provjeriti usvojeno znanje određenog programskog koncepta, a samim time niti izmjeriti učinak načela raščlanjivanja u formi animacije linearnog kretanja kornjače, na zapamćivanje i razumijevanje sadržaja. Rezultati trećeg i petog zadatka pokazali su nedovoljnu razinu razumijevanja gotovih procedura s promjenjivim ulaznim vrijednostima, te upotrebu REPEAT petlje u pisanju programa.

5.5.2 Testiranje razlika između eksperimentalne i kontrolne skupine

S obzirom na deskriptivne pokazatelje koji su ukazali da ne postoji statistička normalnost distribucija, za analizu razlika korištena je neparametrijska statistika, odnosno u ovom slučaju Mann-Whitneyev test. Rezultati analiza prikazani su u tablici 43.

Tablica 43. Testiranje razlika između eksperimentalne i kontrolne skupine u pogledu zapamćivanja i razumijevanja sadržaja

| Varijabla | Skupina | N | Pros. rang | U | P | r |
|------------------------------|-----------------|----|---------------|--------|-------|-------|
| 2. tjedan – Zapamćivanje | Eksperimentalna | 50 | 46,47 | 1048,5 | 0,266 | 0,112 |
| | Kontrolna | 48 | 52,66 | | | |
| 2. tjedan – Razumijevanje | Eksperimentalna | 50 | 48,74 | 1162 | 0,782 | 0,028 |
| | Kontrolna | 48 | 50,29 | | | |
| 2. tjedan – UKUPNO | Eksperimentalna | 50 | 46,39 | 1044,5 | 0,267 | 0,112 |
| | Kontrolna | 48 | 52,74 | | | |

U – rezultat Mann-Whitney testa

p – statistička značajnost

r – koeficijent veličine efekta (računa se iz rezultata Mann-Whitneyevog testa po formuli $r = \frac{z}{\sqrt{N}}$)

Rezultati provedenih analiza pokazuju kako u svim analizama nije dobivena statistički značajna razlika u broju ostvarenih bodova na zadacima objektivnog tipa. Uvidom u veličine efekata pokazuje se da se radi o niskim efektima. Sve dosadašnje razlike koje su se pojavljivale između eksperimentalne i kontrolne skupine pokazale su se statistički beznačajnim.

5.5.3 Testiranje razlika po godinama studija

Za analizu razlika po godinama korišten je Kruskal-Wallisov test kao neparametrijska alternativa analizi varijance s Mann-Whitneyevim testom za post hoc testiranje razlika među pojedinim skupinama. Kako neparametrijska statistika ne omogućuje složene faktorijske nacрте, analize su provedene zasebno za svaku skupinu i ukupno. Rezultati provedenih analiza prikazani su u tablici 44.

Tablica 44. Rezultati testiranja razlika po pripadnosti studijskoj godini

| Varijabla | Skupina | Grupa | N | Medijan | Prosj. rang | X ² | Mann Whitney test | | |
|---------------------------|-----------------|-------|----|---------|-------------|----------------|-------------------|------------------|------------------|
| | | | | | | | r ₃₋₄ | r ₃₋₅ | r ₄₋₅ |
| 2. tjedan – Zapamćivanje | Eksperimentalna | 3 | 14 | 6 | 28,79 | 6,387* | 0,13 | 0,407* | 0,323 |
| | | 4 | 16 | 6,5 | 30,19 | | | | |
| | | 5 | 20 | 6 | 19,45 | | | | |
| | Kontrolna | 3 | 14 | 6 | 25,14 | 1,868 | | | |
| | | 4 | 15 | 6,5 | 27,80 | | | | |
| | | 5 | 19 | 6 | 21,42 | | | | |
| | Ukupno | 3 | 28 | 6 | 53,54 | 8,038* | 0,114 | 0,276* | 0,290* |
| | | 4 | 31 | 6,5 | 57,77 | | | | |
| | | 5 | 39 | 6 | 40,03 | | | | |
| 2. tjedan – Razumijevanje | Eksperimentalna | 3 | 14 | 1 | 25,54 | 0,207 | | | |
| | | 4 | 16 | 0,66 | 24,28 | | | | |
| | | 5 | 20 | 1 | 26,45 | | | | |
| | Kontrolna | 3 | 14 | 0,75 | 21,25 | 2,196 | | | |
| | | 4 | 15 | 1 | 28,57 | | | | |
| | | 5 | 19 | 1 | 23,68 | | | | |
| | Ukupno | 3 | 28 | 0,75 | 46,16 | 0,719 | | | |
| | | 4 | 31 | 1 | 52,27 | | | | |
| | | 5 | 39 | 1 | 49,69 | | | | |
| 2. tjedan – UKUPNO | Eksperimentalna | 3 | 14 | 6,88 | 27,96 | 2,6 | | | |
| | | 4 | 16 | 7,12 | 28,41 | | | | |
| | | 5 | 20 | 6,25 | 21,45 | | | | |
| | Kontrolna | 3 | 14 | 7 | 22,96 | 2,342 | | | |
| | | 4 | 15 | 7,5 | 29,03 | | | | |
| | | 5 | 19 | 7 | 22,05 | | | | |
| | Ukupno | 3 | 28 | 7 | 50,16 | 4,254 | | | |
| | | 4 | 31 | 7,25 | 57,05 | | | | |
| | | 5 | 39 | 6,75 | 43,03 | | | | |

X² – rezultat Kruskal-Wallis testa

r – koeficijent veličine efekta (računa se iz rezultata Mann-Whitneyevog testa po formuli $r = \frac{z}{\sqrt{N}}$)

* p<0,05

Dobiveni rezultati pokazuju kako postoje statistički značajne razlike kod zadataka zapamćivanja ($X^2=6,387$) za eksperimentalnu skupinu ispitanika te sve ispitanike zajedno ($X^2=8,038$). U kontrolnoj skupini nisu dobivene statistički značajne razlike po studijskim godinama.

U eksperimentalnoj skupini Mann-Whitneyevim testom utvrđeno je kako postoje razlike između treće i pete godine studija na zadacima zapamćivanja, pri čemu su studenti treće godine ostvarili statistički značajno bolje rezultate u odnosu na studente pete godine i ova veličina efekta je umjerena ($r=0,407$).

Kada su se svi ispitanici uzeli zajedno, na zadacima zapamćivanja dobivene su razlike između studenata treće i pete godine ($r=0,276$), te između studenata četvrte i pete godine ($r=0,290$). U oba slučaja studenti pete godine ostvaruju niži rezultat u odnosu na treću i četvrtu godinu i veličine efekata su između niskih i umjerenih. Između studenata treće i četvrte godine nije utvrđena statistički značajna razlika.

5.6 Analiza rezultata provedenog testiranja za prvi i drugi tjedan eksperimentalnog programa

5.6.1 Deskriptivni podatci

Kako su deskriptivni podatci za pojedine zadatke već ranije prikazani, ovdje su prikazani samo deskriptivni podatci za skale.

Ukupan rezultat niza zadataka objektivnog tipa formiran je kao suma bodova na pojedinim zadatcima. Radi kasnijih analiza formirana su tri ukupna rezultata: rezultat za zadatke koji mjere zapamćivanje sadržaja (14 bodova), rezultat za zadatke koji mjere razumijevanje sadržaja (7 bodova) i rezultat za sve zadatke (21 bod). Deskriptivni pokazatelji za niz zadataka objektivnog tipa prikazani su u tablici 45.

Tablica 45. Prikaz ukupnih rezultata eksperimentalne i kontrolne skupine za zadatke zapamćivanja i razumijevanja sadržaja za I. i II. tjedan istraživanja

| Varijabla | Skupina | N | min | max | M | SD | C | Q1 | Q3 | Skew | Kurt | KS-z | p |
|--------------------------------------|-----------------|----|-----|---------|-------|-------|------|------|------|--------|--------|-------|-------|
| 1.i 2.tjedan – Zadatci zapamćivanja | Eksperimentalna | 50 | 3,5 | 13 | 9,36 | 2,322 | 9,6 | 8,0 | 11,0 | -0,719 | 0,204 | 0,138 | 0,018 |
| | Kontrolna | 48 | 5 | 14 | 10,06 | 1,711 | 10,3 | 9,1 | 11,0 | -0,665 | 1,245 | 0,110 | 0,191 |
| | Ukupno | 98 | 3,5 | 14 | 9,70 | 2,065 | 10,0 | 8,9 | 11,0 | -0,834 | 0,833 | 0,122 | 0,001 |
| 1.i 2.tjedan – Zadatci razumijevanja | Eksperimentalna | 50 | 0 | 6,875 | 4,19 | 1,493 | 4,0 | 3,0 | 5,1 | -0,366 | 0,425 | 0,132 | 0,030 |
| | Kontrolna | 48 | 2 | 6,9125 | 4,48 | 1,206 | 4,4 | 4,0 | 5,2 | -0,024 | -0,115 | 0,134 | 0,031 |
| | Ukupno | 98 | 0 | 6,9125 | 4,33 | 1,360 | 4,0 | 3,4 | 5,2 | -0,314 | 0,430 | 0,117 | 0,002 |
| 1.i 2.tjedan – UKUPNO | Eksperimentalna | 50 | 5,5 | 19,375 | 13,55 | 3,443 | 13,6 | 11,4 | 16,3 | -0,381 | -0,280 | 0,076 | 0,200 |
| | Kontrolna | 48 | 8 | 20,1375 | 14,54 | 2,426 | 14,9 | 13,0 | 16,0 | -0,224 | 0,332 | 0,086 | 0,200 |
| | Ukupno | 98 | 5,5 | 20,1375 | 14,04 | 3,014 | 14,2 | 12,0 | 16,1 | -0,500 | 0,249 | 0,069 | 0,200 |

min,max – najniži i najviši ostvareni rezultat

M – aritmetička sredina

SD – standardna devijacija

C – medijan

Q1 – rezultat na prvom kvartilu

Q3 – rezultat na trećem kvartilu

Skew – Asimetrija (engl. Skewness) distribucije

Kurt – Spljoštenost (Kurtozija, engl. Kurtosis)

KS-z – Kolmogorov-Smirnovljev test normaliteta distribucije

p – Statistička značajnost KS testa (ako je $p < 0,05$ distribucija nije normalna)

Iz tablice 45 je vidljivo da nisu nađene statistički značajne razlike između kontrolne i eksperimentalne skupine u pogledu rješavanja zadataka zapamćivanja i razumijevanja sadržaja za I. i II. tjedan istraživanja.

5.6.2 Testiranje razlika između eksperimentalne i kontrolne skupine

Deskriptivni pokazatelji ukazali su da za zadatke zapamćivanja i razumijevanja sadržaja distribucija nije normalna, dok je za ukupan rezultat dobivena statistička normalnost distribucije. Ipak, kako bi se zadržala konzistentnost analiza za sva testiranja razlika, korištena je neparametrijska statistika, odnosno Mann-Whitneyev test. Rezultati analiza prikazani su u tablici 46.

Tablica 46. Testiranje razlika između eksperimentalne i kontrolne skupine u pogledu zapamćivanja i razumijevanja sadržaja

| Varijabla | Skupina | N | Pros. rang | U | p | r |
|----------------------------------|-----------------|----|---------------|--------|-------|-------|
| 1.i 2. tjedan – Zapamćivanje | Eksperimentalna | 50 | 45,46 | 998 | 0,150 | 0,145 |
| | Kontrolna | 48 | 53,71 | | | |
| 1.i 2. tjedan – Razumijevanje | Eksperimentalna | 50 | 46,55 | 1052,5 | 0,291 | 0,107 |
| | Kontrolna | 48 | 52,57 | | | |
| 1.i 2. tjedan – UKUPNO | Eksperimentalna | 50 | 45,71 | 1010,5 | 0,178 | 0,136 |
| | Kontrolna | 48 | 53,45 | | | |

U – rezultat Mann-Whitney testa

p – statistička značajnost

r – koeficijent veličine efekta (računa se iz rezultata Mann-Whitneyevog testa po formuli $r = \frac{z}{\sqrt{N}}$)

Rezultati provedenih analiza pokazuju kako u svim analizama nije dobivena statistički značajna razlika u broju ostvarenih bodova na zadacima objektivnog tipa. Uvidom u veličine efekata pokazuje se da se radi o niskim efektima.

5.6.3 Testiranje razlika po godinama studija

Za analizu razlika po godinama studija korišten je Kruskal-Wallisov test kao neparametrijska alternativa analizi varijance s Mann-Whitneyevim testom za post hoc testiranje razlika među pojedinim skupinama. Kako neparametrijska statistika ne omogućuje složene faktorijalne nacрте, analize su provedene zasebno za svaku skupinu i ukupno. Rezultati provedenih analiza prikazani su u tablici 47.

Tablica 47. Rezultati testiranja razlika po pripadnosti studijskoj godini

| Varijabla | Skupina | Grupa | N | Medijan | Prosj. rang | X ² |
|------------------------------|-----------------|-------|----|---------|-------------|----------------|
| 1.i 2.tjedan – Zapamćivanje | Eksperimentalna | 3 | 14 | 10,375 | 30,79 | 2,582 |
| | | 4 | 16 | 8,875 | 23,69 | |
| | | 5 | 20 | 9,25 | 23,25 | |
| | Kontrolna | 3 | 14 | 10,375 | 25,32 | 0,363 |
| | | 4 | 15 | 9,75 | 22,70 | |
| | | 5 | 19 | 10,5 | 25,32 | |
| | Ukupno | 3 | 28 | 10,375 | 55,09 | 1,576 |
| | | 4 | 31 | 9,5 | 46,39 | |
| | | 5 | 39 | 10 | 47,96 | |
| | Eksperimentalna | 3 | 14 | 4 | 24,93 | 0,085 |
| | | 4 | 16 | 4,375 | 25,09 | |
| | | 5 | 20 | 4 | 26,23 | |
| 1.i 2.tjedan – Razumijevanje | Kontrolna | 3 | 14 | 4 | 23,57 | 0,818 |
| | | 4 | 15 | 5 | 27,17 | |
| | | 5 | 19 | 4,375 | 23,08 | |
| | Ukupno | 3 | 28 | 4 | 48,30 | 0,254 |
| | | 4 | 31 | 4,75 | 51,60 | |
| | | 5 | 39 | 4 | 48,69 | |
| 1.i 2.tjedan – UKUPNO | Eksperimentalna | 3 | 14 | 14,375 | 28,82 | 1,019 |
| | | 4 | 16 | 13,5 | 23,97 | |
| | | 5 | 20 | 13 | 24,40 | |
| | Kontrolna | 3 | 14 | 15 | 25,50 | 0,106 |
| | | 4 | 15 | 14 | 23,90 | |
| | | 5 | 19 | 14,875 | 24,24 | |
| | Ukupno | 3 | 28 | 14,5 | 52,89 | 0,566 |
| | | 4 | 31 | 13,5 | 47,82 | |
| | | 5 | 39 | 14,225 | 48,40 | |

X² – rezultat Kruskal-Wallis testa

* p<0,05

Rezultati provedenih analiza pokazuju da među skupinama nisu dobivene statistički značajne razlike.

5.7 Analiza rezultata provedenog testiranja za treći tjedan eksperimentalnog programa

5.7.1 Deskriptivni podatci

U trećem tjednu eksperimentalnog programa ispitanici su pregledali multimedijски sadržaj iz nastavnih tema (10 minuta): *Tipovi podataka (numerički, znakovni, liste); Algoritmi koji koriste različite tipove podataka.* Zatim su rješavali odgovarajuće zadatke objektivnog tipa za provjeru znanja (15 minuta): 3 zadatka za mjerenje zapamćivanja sadržaja i 3 zadatka za mjerenje razumijevanja sadržaja. Nakon što su riješili zadatke ispunili su upitnik za subjektivnu procjenu uloženog mentalnog napora kojeg su uložili na pregledavanje i upotrebu multimedijskog sadržaja (5 minuta).

Zbog naravi sadržaja u prva dva zadataka koji su obuhvaćali osnovne naredbe za rad s riječima i listama (elementarno znanje), u eksperimentalnoj skupini se radi smanjenja esencijalnog kognitivnog opterećenja nije primijenilo načelo raščlanjivanja.

U tablici 48 prikazani su deskriptivni podatci za zadatke u trećem tjednu istraživanja.

Tablica 48. Prikaz rezultata u trećem tjednu istraživanja za obje skupine (eksperimentalna i kontrolna)

| Zadatak | Skupina | Deskriptivna statistika | | | | | | | | % ispitanika po broju ostvarenih bodova | | | | | | | |
|--|-----------------|-------------------------|------|------|-------|-----|-----|-----|------|---|------|------|-------|-------|------|------|-------|
| | | N | maxt | M | SD | C | Q1 | Q3 | p | ,0 | ,5 | 1,0 | 2,0 | 3,0 | 4,0 | 5,0 | 5-9 |
| III. Tjedan (Zapamćivanje) 1 zadatak | Eksperimentalna | 50 | 9 | 7,88 | 1,466 | 8,0 | 8,0 | 9,0 | 0,88 | 2,0% | 0,0% | 0,0% | 0,0% | 0,0% | 0,0% | 2,0% | 96,0% |
| | Kontrolna | 48 | 9 | 7,98 | 1,816 | 8,0 | 8,0 | 9,0 | 0,89 | 2,1% | 0,0% | 2,1% | 0,0% | 0,0% | 0,0% | 2,1% | 93,8% |
| | Ukupno | 98 | 9 | 7,93 | 1,639 | 8,0 | 8,0 | 9,0 | 0,88 | 2,0% | 0,0% | 1,0% | 0,0% | 0,0% | 0,0% | 2,0% | 94,9% |
| III. Tjedan (Zapamćivanje) 2 zadatak | Eksperimentalna | 50 | 3 | 2,80 | ,404 | 3,0 | 3,0 | 3,0 | 0,93 | 0,0% | 0,0% | 0,0% | 20,0% | 80,0% | | | |
| | Kontrolna | 48 | 3 | 2,69 | ,468 | 3,0 | 2,0 | 3,0 | 0,90 | 0,0% | 0,0% | 0,0% | 31,3% | 68,8% | | | |
| | Ukupno | 98 | 3 | 2,74 | ,438 | 3,0 | 2,0 | 3,0 | 0,91 | 0,0% | 0,0% | 0,0% | 25,5% | 74,5% | | | |

| | | | | | | | | | | | | | | | | |
|---|-----------------|----|---|------|-------|-----|-----|-----|------|-------|------|-------|------|-------|-------|-------|
| III. Tjedan (Zapamćivanje) 3 zadatak | Eksperimentalna | 50 | 1 | ,12 | ,328 | 0,0 | 0,0 | 0,0 | 0,12 | 88,0% | 0,0% | 12,0% | | | | |
| | Kontrolna | 48 | 1 | ,11 | ,314 | 0,0 | 0,0 | 0,0 | 0,11 | 87,5% | 2,1% | 10,4% | | | | |
| | Ukupno | 98 | 1 | ,12 | ,319 | 0,0 | 0,0 | 0,0 | 0,12 | 87,8% | 1,0% | 11,2% | | | | |
| III. Tjedan (Razumijevanje) 4 zadatak | Eksperimentalna | 50 | 1 | ,12 | ,312 | 0,0 | 0,0 | 0,0 | 0,12 | 86,0% | 4,0% | 10,0% | | | | |
| | Kontrolna | 48 | 1 | ,06 | ,245 | 0,0 | 0,0 | 0,0 | 0,06 | 93,8% | 0,0% | 6,3% | | | | |
| | Ukupno | 98 | 1 | ,09 | ,281 | 0,0 | 0,0 | 0,0 | 0,09 | 89,8% | 2,0% | 8,2% | | | | |
| III. Tjedan (Razumijevanje) 5 zadatak | Eksperimentalna | 50 | 1 | ,03 | ,157 | 0,0 | 0,0 | 0,0 | 0,03 | 96,0% | 2,0% | 2,0% | | | | |
| | Kontrolna | 48 | 1 | ,02 | ,144 | 0,0 | 0,0 | 0,0 | 0,02 | 97,9% | 0,0% | 2,1% | | | | |
| | Ukupno | 98 | 1 | ,03 | ,150 | 0,0 | 0,0 | 0,0 | 0,03 | 96,9% | 1,0% | 2,0% | | | | |
| III. Tjedan (Razumijevanje) 6 zadatak | Eksperimentalna | 50 | 5 | 3,50 | 1,729 | 4,0 | 3,0 | 5,0 | 0,70 | 16,0% | 0,0% | 0,0% | 0,0% | 24,0% | 22,0% | 38,0% |
| | Kontrolna | 48 | 5 | 3,75 | 1,591 | 4,0 | 3,0 | 5,0 | 0,75 | 10,4% | 0,0% | 2,1% | 2,1% | 16,7% | 25,0% | 43,8% |
| | Ukupno | 98 | 5 | 3,62 | 1,659 | 4,0 | 3,0 | 5,0 | 0,72 | 13,3% | 0,0% | 1,0% | 1,0% | 20,4% | 23,5% | 40,8% |

MAXt – teorijski maksimalni broj bodova

M – aritmetička sredina

SD – standardna devijacija

C – medijan

Q1 – rezultat na prvom kvartilu

Q3 – rezultat na trećem kvartilu

p – indeks lakoće zadatka (računa se kao omjer aritmetičke sredine i teorijskog maksimalnog broja bodova u zadatku)

Prvi u nizu zadataka objektivnog tipa mjerio je sintaktičku i semantičku razinu znanja u Logo jeziku – poznavanje osnovnih naredbi za rad s riječima i listama (ITEM, BL, PR, LAST, FIRST, COUNT, BF). Teorijski maksimalni broj bodova na ovom zadatku bio je 9. Kontrolna i eksperimentalna skupina postigle su podjednake rezultate. U kontrolnoj skupini srednja vrijednost ostvarenih bodova iznosila je 7,98 (SD=1,816), a u eksperimentalnoj skupini 7,88 (SD=1,466). Rješivost zadatka bila je vrlo visoka, gdje je u kontrolnoj skupini 93,8% ispitanika ostvarilo maksimalni broj bodova, a u eksperimentalnoj 96% ispitanika.

Drugi u nizu zadataka objektivnog tipa mjerio je sintaktičku i semantičku razinu znanja u Logo jeziku – poznavanje MAKE naredbe za pridruživanje numeričke vrijednosti ili znakovnog niza varijabli. Teorijski maksimalni broj bodova na ovom zadatku bio je 3. Kontrolna i eksperimentalna skupina postigle su podjednake rezultate. U kontrolnoj skupini srednja vrijednost ostvarenih bodova iznosila je 2,69 (SD=0,468), a u eksperimentalnoj skupini 2,80 (SD=0,404). U kontrolnoj skupini maksimalni broj bodova ostvarilo je 68,8% ispitanika, a u eksperimentalnoj nešto više, 80,0% ispitanika.

Treći u nizu zadataka objektivnog tipa mjerio je sintaktičku i semantičku razinu znanja u Logo jeziku – poznavanje programske strukture WHILE petlje, te vještine konkretnog praćenja izvođenja programskog kôda (engl. *code-tracing*), (za stanje varijable $X = 4$) i čitanja programskog kôda (engl. *code-reading*). Teorijski maksimalni broj bodova na ovom zadatku bio je 1. Kontrolna i eksperimentalna skupina postigle su podjednake rezultate. U kontrolnoj skupini srednja vrijednost ostvarenih bodova iznosila je 0,11 (SD=0,314), a u eksperimentalnoj skupini 0,12 (SD=0,328). Rješivost zadatka bila je vrlo niska, gdje je u kontrolnoj skupini 10,4% ispitanika ostvarilo maksimalni broj bodova, a u eksperimentalnoj 12% ispitanika.

Četvrti u nizu zadataka objektivnog tipa mjerio je shematičnu razinu znanja u Logo jeziku – razumijevanje MAKE naredbe i poznavanje programske strukture FOR petlje, te vještine konkretnog praćenja izvođenja programskog kôda i čitanja programskog kôda. Teorijski maksimalni broj bodova na ovom zadatku bio je 1. Rješivost zadatka bila je vrlo niska, iako je eksperimentalna skupina pokazala nešto bolji uspjeh u rješavanju zadatka. U eksperimentalnoj skupini srednja vrijednost ostvarenih bodova iznosila je 0,12 (SD=0,312), a u kontrolnoj skupini 0,06 (SD=0,245). 10% ispitanika u eksperimentalnoj skupini je ostvarilo maksimalni broj bodova, dok je u kontrolnoj skupini to ostvarilo 6,3% ispitanika.

Peti u nizu zadataka objektivnog tipa mjerio je shematičnu razinu znanja u Logo jeziku – razumijevanje MAKE naredbe i poznavanje programske strukture FOR petlje, te vještine konkretnog praćenja izvođenja programskog kôda (za stanje varijable $K = 4$) i čitanja programskog

kôda. Teorijski maksimalni broj bodova na ovom zadatku bio je 1. Kontrolna i eksperimentalna skupina postigle su podjednake rezultate. U kontrolnoj skupini srednja vrijednost ostvarenih bodova iznosila je 0,02 (SD=0,144), a u eksperimentalnoj skupini 0,03 (SD=0,157). Rješivost zadatka bila je ekstremno niska, gdje je u kontrolnoj skupini samo 2,1% ispitanika ostvarilo maksimalni broj bodova, a u eksperimentalnoj 2% ispitanika.

Šesti u nizu zadataka objektivnog tipa mjerio je shematičnu razinu znanja u Logo jeziku – razumijevanje MAKE naredbe i rada algoritma, te vještine konkretnog praćenja izvođenja procedure s promjenjivim ulaznim vrijednostima (zadane vrijednosti varijabli, A = 11, B = 4, C = 7) i čitanja procedure. Teorijski maksimalni broj bodova na ovom zadatku bio je 5. Kontrolna i eksperimentalna skupina postigle su podjednake rezultate. U kontrolnoj skupini srednja vrijednost ostvarenih bodova iznosila je 3,75 (SD=1,591), a u eksperimentalnoj skupini 3,50 (SD=1,729). Rješivost zadatka bila je niska, gdje je u kontrolnoj skupini 43,8% ispitanika ostvarilo maksimalni broj bodova, a u eksperimentalnoj 38% ispitanika.

Ukupan rezultat niza zadataka objektivnog tipa formiran je kao suma bodova na pojedinim zadatcima. Radi kasnijih analiza formirana su tri ukupna rezultata: rezultat za zadatke koji mjere zapamćivanje sadržaja (13 bodova), rezultat za zadatke koji mjere razumijevanje sadržaja (7 bodova) i rezultat za sve zadatke (20 bodova). Deskriptivni pokazatelji za niz zadataka objektivnog tipa prikazani su u tablici 49.

Tablica 49. Prikaz ukupnih rezultata eksperimentalne i kontrolne skupine za zadatke zapamćivanja i razumijevanja sadržaja za III. tjedan istraživanja

| Varijabla | Skupina | N | min | max | M | SD | C | Q1 | Q3 | Skew | Kurt | KS-z | p |
|-----------------------------------|-----------------|----|-----|-----|-------|-------|------|------|------|--------|--------|-------|-------|
| 3. tjedan – Zadatci zapamćivanja | Eksperimentalna | 50 | 3 | 13 | 10,80 | 1,539 | 11,0 | 10,0 | 12,0 | -2,766 | 12,756 | 0,232 | 0,000 |
| | Kontrolna | 48 | 2 | 13 | 10,78 | 2,073 | 11,0 | 10,3 | 12,0 | -2,861 | 9,694 | 0,292 | 0,000 |
| | Ukupno | 98 | 2 | 13 | 10,79 | 1,811 | 11,0 | 10,0 | 12,0 | -2,880 | 10,940 | 0,260 | 0,000 |
| 3. tjedan – Zadatci razumijevanja | Eksperimentalna | 50 | 0 | 7 | 3,65 | 1,861 | 4,0 | 3,0 | 5,0 | -0,907 | 0,083 | 0,203 | 0,000 |
| | Kontrolna | 48 | 0 | 6 | 3,83 | 1,667 | 4,0 | 3,0 | 5,0 | -1,219 | 0,741 | 0,227 | 0,000 |

| | | | | | | | | | | | | | |
|--------------------|-----------------|----|---|----|-------|-------|------|------|------|--------|-------|-------|-------|
| | Ukupno | 98 | 0 | 7 | 3,74 | 1,762 | 4,0 | 3,0 | 5,0 | -1,036 | 0,298 | 0,212 | 0,000 |
| 3. tjedan – UKUPNO | Eksperimentalna | 50 | 8 | 20 | 14,45 | 2,389 | 15,0 | 13,0 | 16,0 | -0,438 | 0,350 | 0,145 | 0,010 |
| | Kontrolna | 48 | 3 | 19 | 14,61 | 3,142 | 16,0 | 14,0 | 16,8 | -1,833 | 3,797 | 0,233 | 0,000 |
| | Ukupno | 98 | 3 | 20 | 14,53 | 2,770 | 15,0 | 13,8 | 16,0 | -1,383 | 2,955 | 0,179 | 0,000 |

min,max – najniži i najviši ostvareni rezultat

M – aritmetička sredina

SD – standardna devijacija

C – medijan

Q1 – rezultat na prvom kvartilu

Q3 – rezultat na trećem kvartilu

Skew – Asimetrija (engl. Skewness) distribucije

Kurt – Spljoštenost (Kurtozija, engl. Kurtosis)

KS-z – Kolmogorov-Smirnovljev test normaliteta distribucije

p – Statistička značajnost KS testa (ako je $p < 0,05$ distribucija nije normalna)

Iz tablice 49 je vidljivo da nisu nađene statistički značajne razlike između kontrolne i eksperimentalne skupine u pogledu rješavanja zadataka zapamćivanja i razumijevanja sadržaja za III. tjedan istraživanja.

Prvi zadatak provjeravao je poznavanje osnovnih naredbi za rad s riječima i listama (ITEM, BL, PR, LAST, FIRST, COUNT, BF) na konkretnim primjerima. Gotovo svi ispitanici su uspješno riješili prvi zadatak, gdje je maksimalno ostvareni broj bodova u kontrolnoj skupini postiglo 93,8% ispitanika, a u eksperimentalnoj 96,0% ispitanika.

Drugi zadatak provjeravao je poznavanje MAKE naredbe za pridruživanje numeričke vrijednosti ili znakovnog niza varijabli na konkretnim primjerima. U programiranju, *izjava pridruživanja* (operator „=“) označava radnju prema kojoj se vrijednost ili rezultat izraza s desne strane operatora „=“ dodjeljuje (kopira) varijabli s lijeve strane operatora „=“. U odnosu na stupanj složenosti zadatka (elementarno znanje MAKE naredbe) i na dostupnost multimedijskog sadržaja za vrijeme rješavanja zadatka rezultati su pokazali relativno nisku rješivost, gdje je maksimalno ostvareni broj bodova u kontrolnoj skupini postiglo 68,8% ispitanika, a u eksperimentalnoj 80,0% ispitanika, a bila je za očekivati stopostotna rješivost zadatka. Kako za sadržaj ovog zadatka nije primijenjeno načelo raščlanjivanja u eksperimentalnoj skupini, postoji mogućnost da određeni broj ispitanika nije razumio način rada MAKE naredbe iz prikazanog objašnjenja ili je imao neadekvatni mentalni model programskog koncepta „pridruživanja vrijednosti nepoznanici ili varijabli (engl. *value assignment*)“, na kojeg nije utjecala multimedijaska instruktivna poruka. *Izjava pridruživanja* (operator „=“) čini jednu od niza miskoncepcija osnovnih programskih konceptata (Sorva, J., 2012, str. 359-368), koju ispitanici mogu posjedovati u procesu programiranja. Na primjer, *izjava pridruživanja* može se interpretirati kao matematička jednakost, a ne kao operator pridruživanja (Ma, L., 2007). Takva miskoncepcija, kao rezultat neodrživog mentalnog modela kojeg ispitanici podržavaju, ako se ne promijeni, negativno utječe na daljnji proces programiranja.

Treći, četvrti i peti zadatak provjeravali su poznavanje programskih struktura WHILE i FOR petlji, te vještine konkretnog praćenja izvođenja programskog kôda (zadano stanje varijabli) i čitanja programskog kôda. Iako je treći zadatak predstavljao „presliku“ multimedijskog prikaza WHILE petlje, samo s drugim vrijednostima varijabli, obje skupine postigle su vrlo niske rezultate, što nije bilo za očekivati zbog primijenjenog načela raščlanjivanja. U četvrtom i osobito petom zadatku koji je provjeravao vještine praćenja izvođenja programskog kôda sa FOR petljom za zadanu vrijednost, rješivost zadatka bila je ekstremno niska. Prema rezultatima se može uočiti kako načelo raščlanjivanja izvođenja WHILE i FOR petlji u eksperimentalnoj skupini nije pridonijelo unaprjeđenju razumijevanja tih programskih struktura. Kao i kod MAKE naredbe, velika je mogućnost da ispitanici uopće ne posjeduju mentalne modele programskih struktura WHILE i FOR petlji ili imaju unaprijed formirane neadekvatne mentalne modele razvijene na temelju miskoncepcija, kao što je vjerovanje da se vrijednost kontrolne varijable (K) mijenja unutar „tijela“ FOR petlje, umjesto da se povećava svakim prolazom (iteracijom), (Putnam, R. i sur., 1984). Ova se miskoncepcija,

ako je i postojala, pokušala riješiti načelom raščlanjivanja u eksperimentalnoj skupini što se pokazalo neuspješnim. Neadekvatni mentalni modeli mogli su biti formirani u osnovnoj ili srednjoj školi, te na kolegiju „Programiranje“ na četvrtoj godini studija.

Šesti zadatak provjeravao je razumijevanje rada algoritma kroz vještinu konkretnog praćenja izvođenja procedure s promjenjivim ulaznim vrijednostima (zadane vrijednosti varijabli, $A = 11$, $B = 4$, $C = 7$) i čitanja procedure. Praćenje izvođenja procedure ovisilo je o upotrebi održivih mentalnih modela koncepata varijable, osnovnih naredbi za rad s riječima i listama, MAKE naredbe (prvi i drugi zadatak), te razumijevanja izvođenja numeričkih operacija nad vrijednostima varijabli. Rješivost zadatka bila je niska u obje skupine, što ukazuje kako načelo raščlanjivanja nije imalo značajnog utjecaja na unaprjeđenje razumijevanja sadržaja. Razlog tome mogu biti neuspješno formirani mentalni modeli ili upotreba već postojećih neodrživih mentalnih modela stečenih u ranijem obrazovanju. U bilo kojem slučaju, ispitanici nisu bili u stanju logički i matematički pratiti izvođenje procedure, odnosno razumjeti izjave pridruživanja vrijednosti varijablama i izvođenje numeričkih operacija nad njihovim vrijednostima. Ovaj problem pokazao se univerzalnim u mnogim istraživanjima, u kojima studenti nisu bili sposobni „*linearно pratiti izvođenje programskog kôda*“ (Kaczmarczyk, L. C. i sur., 2010, str. 109), pa čak niti razumjeti izvođenje triju uzastopnih linija programskog kôda s izmjenama vrijednosti varijabli (Simon, 2011, prema Sorva, J., 2012).

5.7.2 Testiranje razlika između eksperimentalne i kontrolne skupine

Deskriptivni pokazatelji ukazali su da za zadatke zapamćivanja i razumijevanja sadržaja distribucija nije normalna, dok je za ukupan rezultat dobivena statistička normalnost distribucije. Ipak, kako bi se zadržala konzistentnost analiza za sva testiranja razlika, korištena je neparametrijska statistika, odnosno Mann-Whitneyev test. Rezultati analiza prikazani su u tablici 50.

Tablica 50. Testiranje razlika između eksperimentalne i kontrolne skupine u pogledu zapamćivanja i razumijevanja sadržaja

| Varijabla | Skupina | N | Pros. rang | U | p | r |
|------------------------------|-----------------|----|---------------|--------|-------|-------|
| 3. tjedan – Zapamćivanje | Eksperimentalna | 50 | 47,17 | 1083,5 | 0,388 | 0,087 |
| | Kontrolna | 48 | 51,93 | | | |
| 3. tjedan – Razumijevanje | Eksperimentalna | 50 | 47,97 | 1123,5 | 0,573 | 0,057 |
| | Kontrolna | 48 | 51,09 | | | |
| 3. tjedan – UKUPNO | Eksperimentalna | 50 | 45,79 | 1014,5 | 0,182 | 0,135 |
| | Kontrolna | 48 | 53,36 | | | |

U – rezultat Mann-Whitney testa

p – statistička značajnost

r – koeficijent veličine efekta (računa se iz rezultata Mann-Whitneyevog testa po formuli $r = \frac{z}{\sqrt{N}}$)

Rezultati provedenih analiza pokazuju da u svim analizama nije dobivena statistički značajna razlika u broju ostvarenih bodova na zadacima objektivnog tipa. Uvidom u veličine efekata pokazuje se da se radi o vrlo niskim i niskim efektima.

5.7.3 Testiranje razlika po godinama studija

Za analizu razlika po godinama korišten je Kruskal-Wallisov test kao neparametrijska alternativa analizi varijance s Mann-Whitneyevim testom za post hoc testiranje razlika među pojedinim skupinama. Zato što neparametrijska statistika ne omogućuje složene faktorijalne nacрте, analize su provedene zasebno za svaku skupinu i ukupno. Rezultati provedenih analiza prikazani su u tablici 51.

Tablica 51. Rezultati testiranja razlika po pripadnosti studijskoj godini

| Varijabla | Skupina | Grupa | N | Medijan | Prosj. rang | X ² |
|--------------------------|-----------------|-------|----|---------|-------------|----------------|
| 3.tjedan – Zapamćivanje | Eksperimentalna | 3 | 14 | 11 | 28,75 | 1,686 |
| | | 4 | 16 | 11 | 22,16 | |
| | | 5 | 20 | 11 | 25,90 | |
| | Kontrolna | 3 | 14 | 11,5 | 25,64 | 0,172 |
| | | 4 | 15 | 11 | 24,47 | |
| | | 5 | 19 | 11 | 23,68 | |
| | Ukupno | 3 | 28 | 11 | 53,55 | 1,035 |
| | | 4 | 31 | 11 | 46,37 | |
| | | 5 | 39 | 11 | 49,08 | |
| 3.tjedan – Razumijevanje | Eksperimentalna | 3 | 14 | 4 | 25,54 | 0,099 |
| | | 4 | 16 | 4 | 24,66 | |
| | | 5 | 20 | 4,5 | 26,15 | |
| | Kontrolna | 3 | 14 | 4 | 21,54 | 1,474 |
| | | 4 | 15 | 4 | 23,87 | |
| | | 5 | 19 | 5 | 27,18 | |
| | Ukupno | 3 | 28 | 4 | 46,54 | 1,015 |
| | | 4 | 31 | 4 | 47,94 | |
| | | 5 | 39 | 5 | 52,87 | |
| 3.tjedan – UKUPNO | Eksperimentalna | 3 | 14 | 15 | 27,61 | 0,433 |
| | | 4 | 16 | 14 | 24,31 | |
| | | 5 | 20 | 14,5 | 24,98 | |
| | Kontrolna | 3 | 14 | 15 | 23,32 | 0,37 |
| | | 4 | 15 | 16 | 23,73 | |
| | | 5 | 19 | 16 | 25,97 | |
| | Ukupno | 3 | 28 | 15 | 49,82 | 0,216 |
| | | 4 | 31 | 15 | 47,65 | |
| | | 5 | 39 | 16 | 50,74 | |

X² – rezultat Kruskal-Wallis testa

* p<0,05

Rezultati provedenih analiza pokazuju da među skupinama nisu dobivene statistički značajne razlike.

5.8 Evaluacija

5.8.1 Mentalni napor

Subjektivna procjena uloženog mentalnog napora na pregledavanje i upotrebu multimedijskog sadržaja mjerila su u trajanju od 5 minuta na kraju svakog tjedna istraživanja. Deskriptivna statistika za varijable mentalnog napora prikazana je u tablici 52.

Tablica 52. Mjerenje mentalnog napora studenata tijekom sva tri tjedna istraživanja (eksperimentalna i kontrolna skupina)

| Varijabla | Skupina | N | min | max | M | SD | C | Q1 | Q3 | Skew | Kurt | KS-z | p |
|----------------------------|-----------------|----|-----|-----|------|-------|-----|-----|-----|--------|--------|-------|-------|
| 1. tjedan – Mentalni napor | Eksperimentalna | 50 | 1 | 7 | 4,26 | 1,259 | 4,0 | 4,0 | 5,0 | -0,260 | 0,803 | 0,198 | 0,000 |
| | Kontrolna | 47 | 2 | 6 | 4,38 | 1,033 | 4,0 | 4,0 | 5,0 | -0,228 | -0,235 | 0,198 | 0,000 |
| | Ukupno | 97 | 1 | 7 | 4,32 | 1,151 | 4,0 | 4,0 | 5,0 | -0,279 | 0,556 | 0,195 | 0,000 |
| 2. tjedan – Mentalni napor | Eksperimentalna | 50 | 2 | 7 | 4,70 | 1,216 | 5,0 | 4,0 | 6,0 | -0,454 | -0,123 | 0,217 | 0,000 |
| | Kontrolna | 48 | 3 | 7 | 5,04 | 0,922 | 5,0 | 4,0 | 6,0 | 0,085 | -0,685 | 0,185 | 0,000 |
| | Ukupno | 98 | 2 | 7 | 4,87 | 1,090 | 5,0 | 4,0 | 6,0 | -0,413 | 0,118 | 0,201 | 0,000 |
| 3. tjedan – Mentalni napor | Eksperimentalna | 49 | 2 | 7 | 5,43 | 1,061 | 6,0 | 5,0 | 6,0 | -0,843 | 1,227 | 0,236 | 0,000 |
| | Kontrolna | 48 | 3 | 7 | 5,56 | 1,147 | 6,0 | 5,0 | 6,0 | -0,557 | -0,294 | 0,211 | 0,000 |
| | Ukupno | 97 | 2 | 7 | 5,49 | 1,100 | 6,0 | 5,0 | 6,0 | -0,657 | 0,310 | 0,223 | 0,000 |

min,max – najniži i najviši ostvareni rezultat

M – aritmetička sredina

SD – standardna devijacija

C – medijan

Q1 – rezultat na prvom kvartilu

Q3 – rezultat na trećem kvartilu

Skew – Asimetrija (engl. Skewness) distribucije

Kurt – Spljoštenost (Kurtozija, engl. Kurtosis)

KS-z – Kolmogorov Smirnovljev test normaliteta distribucije

p – Statistička značajnost KS testa (ako je $p < 0,05$ distribucija nije normalna)

Iz tablice 52 je vidljivo kako su ispitanici u prvom i drugom tjednu istraživanja subjektivno procijenili uloženi mentalni napor relativno visokom ocjenom u kontrolnoj ($M_I=4,38$, $SD_I=1,033$; $M_{II}=5,04$, $SD_{II}=0,922$) i eksperimentalnoj ($M_I=4,26$, $SD_I=1,259$; $M_{II}=4,70$, $SD_{II}=1,216$) skupini. Kognitivni zahtjevi postavljeni ispitanicima obuhvaćali su razumijevanje i primjenu: (1) osnovnih naredbi (FD, BK, RT, LT, PU, PD); (2) naredbi za rad s više kornjača (SETTURTLES, TELL, ASK); (3) programske strukture REPEAT petlje, te vještine konkretnog praćenja izvođenja procedure (engl. *code-tracing*), (rad procedure s nepromjenjivim vrijednostima ili promjenjivim ulaznim vrijednostima), čitanja procedure (engl. *code-reading*) i pisanja procedure (engl. *code-writing*). U trećem tjednu istraživanja, subjektivna procjena uloženog mentalnog napora pokazala se još višom u kontrolnoj ($M_{III}=5,56$, $SD_{III}=1,147$) i eksperimentalnoj ($M_{III}=5,43$, $SD_{III}=1,061$) skupini. Kognitivni zahtjevi postavljeni ispitanicima obuhvaćali su razumijevanje i primjenu: (1) osnovnih naredbi za rad s riječima i listama (ITEM, BL, PR, LAST, FIRST, COUNT, BF); (2) MAKE naredbe za pridruživanje numeričke vrijednosti ili znakovnog niza varijabli (nepoznanici); (3) programske strukture WHILE petlje; (4) programske strukture FOR petlje; (5) rad algoritma, te vještine konkretnog praćenja izvođenja programskog kôda i čitanja programskog kôda.

Prema *teoriji kognitivnog opterećenja* (Sweller, J. i Chandler, P., 1994), ispitanik treba imati dovoljno dostupnog kapaciteta radne memorije radi sposobnosti angažiranja u dublje kognitivne procese koji su relevantni za proces usvajanja znanja, čime se potiče sadržajno relevantno kognitivno opterećenje. To ujedno zahtjeva eliminaciju sadržajno irelevantnog opterećenja i smanjenje esencijalnog opterećenja u razvoju multimedijske instruktivne poruke (Sweller, J., van Merriënboer, J. J. G. i Paas, F. G. W. C., 1998; Mayer, R. E., 2009, prema Kassim, H., 2011; Mayer, R. E. i Alexander, P. A., 2011). Maksimalno moguća eliminacija sadržajno irelevantnog opterećenja ostvarena je primjenom

KTMUZ načela u razvoju MIPL-a. Esencijalno kognitivno opterećenje nije moguće eliminirati, već kontrolirati upotrebom jednostavnijih zadataka ili izostavljanjem određenog dijela interaktivnih elemenata, što se primijenilo u razvoju MIPL-a. Također, ispitanici kontrolne i eksperimentalne skupine su imali na raspolaganju sadržaj poruke za vrijeme rješavanja zadataka, što je predstavljalo pomoćno kognitivno sredstvo odnosno vanjsku memoriju u procesu učenja. Pri tome, nad strukturom sadržaja MIPL-a eksperimentalne skupine dodatno je primijenjeno načelo raščlanjivanja, realizirano načelima signalizacije, animacije i interaktivnosti.

Prema dobivenim rezultatima (tablica 52) može se vidjeti da su prikazani sadržaji MIPL-a, za kontrolnu i eksperimentalnu skupinu, tijekom sva tri tjedna istraživanja predstavljali visoko esencijalno opterećenje kao rezultat postavljenih kognitivnih zahtjeva na kapacitet radne memorije ispitanika. Kognitivni zahtjevi, kao odraz složenosti poruke, obuhvaćali su dva aspekta: (1) zapamćivanje i razumijevanje niza programskih koncepata i (2) geometrijsko predznanje. Pretpostavka je da su ispitanici u prvom i drugom tjednu istraživanja, zbog neadekvatne razine geometrijskog predznanja u poznavanju kutova, likova (trokut, kvadrat, šesterokut, paralelogram, romb) i plohe (kocka), veći dio kognitivnog kapaciteta posvetili pregledavanju i razumijevanju geometrijskog dijela sadržaja s matematičkog aspekta, zbog čega nisu imali dovoljno preostalog kapaciteta za proces usvajanja programskih koncepata, što je i bila temeljna svrha MIPL-a. Geometrijski sadržaj MIPL-a predstavlja (vizualni) rezultat izvođenja programskih naredbi i struktura i samim time pomoćno kognitivno sredstvo u procesu usvajanja određenog (apstraktnog) programskog koncepta. Ako matematičko predznanje nije zadovoljeno, javljaju se poteškoće u povezivanju apstraktnih naredbi i geometrijskih rezultata. Zbog sveukupnog opterećenja, nastalog iz kognitivnih zahtjeva istovremenog usvajanja programskih koncepata i odgovarajućeg geometrijskog dijela sadržaja, mentalni napor pokazao se visokim. U trećem tjednu istraživanja, procjena mentalnog napora pokazala se višom u odnosu na prethodna dva tjedna, što može biti rezultat naravi sadržaja poruke koja nije zahtijevala geometrijsko, već logičko predznanje, te formiranje ili modificiranje i primjenu održivih mentalnih modela apstraktnih programskih koncepata.

Mjerenjem mentalnog napora željelo se dobiti uvid u subjektivnu procjenu postavljenih kognitivnih zahtjeva na kapacitet radne memorije ispitanika sadržajem MIPL-a. Pri tome, ispitanicima je u svakom susretu rečeno da će trebati procijeniti uloženi mentalni napor čime se njihova pažnja usmjerila na procjenjivanje cijelog sadržaja MIPL-a za pojedinačni tjedan, a ne samo određenog dijela sadržaja poruke koji im je predstavljao najviše poteškoća u razumijevanju. Iako su rezultati pokazali visoki mentalni napor tijekom sva tri tjedna, značajan nedostatak

ovakvog načina mjerenja leži u činjenici što ono nije provedeno nakon svakog zadatka, što bi uz dobivene ishode učenja (rezultati zadataka zapamćivanja i razumijevanja sadržaja) omogućilo usporedbu različitih komponenti instrukcijske poruke (vrsta i složenost zadataka) prema njihovom doprinosu kognitivnom opterećenju u procesu učenja (van Gog, T. i sur., 2012). Međutim, takva vrsta mjerenja izlazi izvan okvira ovog rada i ostaje kao mogućnost za buduća istraživanja.

Na svim trima varijablama (mentalni naponi tijekom tri istraživačka tjedna) distribucija odstupa od normalne te su razlike testirane Mann-Whitneyevim testom (tablica 53).

Tablica 53. Mjerenje mentalnog napora studenata Mann-Whitneyevim testom

| Varijabla | Skupina | N | Prosje. rang | U | p | r |
|----------------------------|-----------------|----|--------------|--------|-------|-------|
| 1. tjedan – Mentalni napor | Eksperimentalna | 50 | 47,59 | 1104,5 | 0,595 | 0,054 |
| | Kontrolna | 47 | 50,50 | | | |
| 2. tjedan – Mentalni napor | Eksperimentalna | 50 | 46,23 | 1036,5 | 0,226 | 0,122 |
| | Kontrolna | 48 | 52,91 | | | |
| 3. tjedan – Mentalni napor | Eksperimentalna | 49 | 47,18 | 1087 | 0,503 | 0,068 |
| | Kontrolna | 48 | 50,85 | | | |

U – rezultat Mann-Whitney testa

p – statistička značajnost

r – koeficijent veličine efekta (računa se iz rezultata Mann-Whitneyevog testa po formuli $r = \frac{z}{\sqrt{N}}$)

Rezultati pokazuju kako niti u jednoj usporedbi nema statistički značajnih razlika među skupinama i veličine efekata su niske ili vrlo niske.

5.8.2 Kategorijalne varijable

U izlaznom upitniku na kraju eksperimentalnog programa, u svrhu evaluacije metodičke i tehničke kvalitete multimedijskog sadržaja te tehničkih sastavnica MIPL-a, dva pitanja su postavljena kao kategorijalne varijable i njihovi su rezultati obrađeni X^2 testom.

Rezultati za prvo kategorijalno pitanje „*Jeste li se do sada susreli s ovakvom vrstom multimedijskog sadržaja za učenje programiranja?*“ prikazani su u tablici 54.

Tablica 54. Rezultati za prvo kategorijalno pitanje

| Pitanje 1 | Skupina | | | | Ukupno | |
|-----------|-----------------|--------|-----------|--------|--------|--------|
| | Eksperimentalna | | Kontrolna | | | |
| | N | % | N | % | N | % |
| Da | 3 | 6,1% | 5 | 10,4% | 8 | 8,2% |
| Ne | 46 | 93,9% | 43 | 89,6% | 89 | 91,8% |
| Ukupno | 49 | 100,0% | 48 | 100,0% | 97 | 100,0% |

Rezultati analize razlika među skupinama ukazuju da ne postoji statistički značajna razlika među ispitanicima prema iskustvu s ovakvom vrstom multimedijskog sadržaja za učenje programiranja ($\chi^2=0,591$; $df=1$; $p=0,442$; $\phi=0,078$). 91,8% ispitanika se izjasnilo kako se nikada ranije nije susrelo s ovakvom vrstom multimedijskog sadržaja za učenje programiranja.

Rezultati za drugo kategorijalno pitanje „*Sviđa li Vam se ovakav način učenja?*“ prikazani su u tablici 55.

Tablica 55. Rezultati za drugo kategorijalno pitanje

| Pitanje 10 | Skupina | | | | Ukupno | |
|------------|-----------------|--------|-----------|--------|--------|--------|
| | Eksperimentalna | | Kontrolna | | | |
| | N | % | N | % | N | % |
| Da | 36 | 72,0% | 33 | 68,8% | 69 | 70,4% |
| Ne znam | 9 | 18,0% | 12 | 25,0% | 21 | 21,4% |
| Ne | 5 | 10,0% | 3 | 6,3% | 8 | 8,2% |
| Ukupno | 50 | 100,0% | 48 | 100,0% | 98 | 100,0% |

Rezultati pokazuju kako niti u ovoj varijabli nema razlika među skupinama ($\chi^2=1,109$; $df=2$; $p=0,601$; $V=0,102$). Oko 70% ispitanika u eksperimentalnoj i kontrolnoj skupini izjasnilo se da im se sviđa ovakav način učenja.

U obrazloženju odgovora na drugo kategorijalno pitanje **ispitanici kontrolne skupine** koji su pozitivno odgovorili na postavljeno pitanje (68,8%) naveli su kako im se sadržaj MIPL-a svidio jer je: drukčiji, koristan, nov, motivirajući, zanimljiv po sadržaju i načinu učenja. Prema njihovima navodima program olakšava i ubrzava učenje, pruža mogućnost ponovnog čitanja ili preslušavanja sadržaja, te vraćanja i zadržavanja na nerazumljivim dijelovima sadržaja. U odgovorima su istakli njima važne elemente MIPL-a: (1) digitalan način prikaza informacija, naspram „*uobičajenog učenja i 'štrebanja' iz udžbenika*“, s vizualnim i zvučnim prikazima bez „*nepotrebnog šarenila koje bi odvučlo pažnju*“; (2) dobra sistematizacija, gdje se primjeri kreću od jednostavnih ka složenima; (3) detaljna analiza svakog postupka i zadatka; (4) „*mogućnost lakšeg predočavanja i memoriranja*“ informacija; (5) pregledni prikaz teorijskog dijela sadržaja potkrijepljenog dodatnim objašnjenjima putem govora; (6) sadržajna povezanost i lakoća vizualne percepcije; (7) jednostavni pristup sadržaju „*gdje se sve nalazi na jednom mjestu*“.

U obrazloženju odgovora na drugo kategorijalno pitanje **ispitanici eksperimentalne skupine** koji su pozitivno odgovorili na postavljeno pitanje (72,0%) naveli su kako im se sadržaj MIPL-a svidio jer je: drukčiji, koristan, zanimljiv, nov, motivirajući, te nije dosadan i suhoparan. U odgovorima su istakli njima važne elemente MIPL-a: (1) digitalan način prikaza informacija, naspram „*klasičnog štrebanja iz knjiga*“ i „*običnog predavanja ili prepisivanja sa slajdova*“, zbog različitih slikovnih i vizualnih prikaza popraćenih govorom; (2) mogućnost određivanja vlastitog tempa učenja pomoću elementa interaktivnosti (određivanje redoslijeda i broja ponavljanja pregledavanja određenog dijela sadržaja poruke); (3) „*postupni način objašnjavanja – 'korak po korak'*“; (4) prikaz teorijskog dijela sadržaja potkrijepljenog konkretnim primjerima sa simultanim prikazom rezultata; (5) mogućnost provjere znanja kroz samostalno rješavanje zadataka; (6) dovoljno vremena na raspolaganju za usvajanje novih koncepata; (7) podrška tradicionalnom poučavanju i mogućnost upotrebe sadržaja izvan nastavnih aktivnosti (kod kuće).

Iako se odgovori ispitanika i kontrolne i eksperimentalne skupine u značajnom omjeru preklapaju, ispitanici kontrolne skupine naglasili su da program zahtijeva „*maksimalnu pažnju i puno više truda*“ i koncentraciju u pregledavanju i primjeni sadržaja, te aktivno uključivanje u proces učenja, kroz sudjelovanje i otkrivanje, a ne samo pasivno slušanje. To može biti rezultat kognitivnog opterećenja nastalog kao kombinacije niske razine geometrijskog

predznanja i nedostatka primijenjenog načela raščlanjivanja nad programerskim sadržajem poruke.

U obrazloženju odgovora na drugo kategorijalno pitanje **ispitanici kontrolne i eksperimentalne skupine** koji su negativno odgovorili na postavljeno pitanje (8,2%) naveli su da im se sadržaj MIPL-a nije svidio zbog: (1) nedostatka vremena za pregledavanje sadržaja i rješavanje zadataka; (2) nedostatka primjera i provjere točnosti zadataka u procesu rješavanja; (3) težine sadržaja koja izaziva frustraciju; (4) nemogućnosti komunikacije s profesorom („živa riječ“, demonstracija) koja će automatski riješiti bilo kakve nedoumice, što program nije u stanju izvršiti, bez obzira na elemente interaktivnosti; (5) „jednosmjerne komunikacije i nedostatka povratnih informacija o svladanosti gradiva“, odnosno nedostatka interakcije između korisnika i sadržaja; (6) otežane koncentracije u radu zbog potrebe samostalnog čitanja i tumačenja sadržaja; (7) nedostatka dodatnih pojašnjenja programskih koncepata (petlje, naredbe) i njihovih međusobnih uloga, značenja i upotrebe.

5.8.3 Evaluacijska varijabla

U izlaznom upitniku na kraju eksperimentalnog programa, u svrhu evaluacije metodičke kvalitete multimedijskog sadržaja postavljeno je pitanje: „*Stekli ste iskustvo učenja na multimedijском sadržaju. Kako mislite da bi se ovaj program mogao unaprijediti?*“

Prema odgovorima ispitanika **kontrolne skupine** unaprjeđenje sadržaja MIPL-a moguće je ostvariti: (1) jasnijim i opširnijim uputama uz dodatne sadržaje pri objašnjavanju zadataka; (2) dodavanjem računalnih zadataka za vježbanje (ne samo na papiru) s povratnom informacijom o postignućima; (3) uvođenjem interaktivnosti u rješavanju zadataka; (4) prebacivanjem sadržaja na sustav za učenje (npr. Moodle) u svrhu samostalnog učenja; (5) dodavanjem animacija, te podsjetnika za „*klikanje*“; (6) dodavanjem aplikacija-animacija koje bi olakšale vizualizaciju i kretanje kornjače; (7) dodavanjem govornih zapisa („*govornog vođenja*“), (8) dodavanjem boja i vidljivih pomaka kornjače; (9) uvođenjem „*vodstva-mentora (ili određenog tutora u programu)*“ koji bi vodio korisnika kroz postupak i pojednostavljivao nerazumljivi dio sadržaja; (10) uvođenjem video zapisa s prikazom objašnjenja koncepata u formi „*korak po korak*“ i kratkih provjera znanja; (11) prethodnim učenjem programiranja u Logo jeziku prije susreta s multimedijском porukom, kako bi se lakše svladali sadržaj i zadatci; (12) uvođenjem usmenih izlaganja profesora za razumijevanje početničkog „*funkcioniranja programiranja*“ i načela rješavanja zadataka; (13) uvođenjem ovog programa u redovitu nastavu.

Prema odgovorima ispitanika **eksperimentalne skupine** unaprijeđenje sadržaj MIPL-a moguće je ostvariti: (1) dodavanjem više različitih primjera s provjerom točnosti riješenih zadataka; (2) dodavanjem više definicija u formi teksta (teorija); (3) dodatnim pojašnjenjima (kao što se „uče slova u prvom razredu“); (4) uvođenjem više primjera i slikovnih prikaza; (5) dodatnim pojednostavljenjem naredbi i zadataka, te učestalijim susretima s ovakvim načinom rada (izvođenje programa više od tri puta); (6) mogućnošću promjene stanja varijabli (npr. za kretanje kornjače) i rješavanjem računalnih zadataka; (7) uvođenjem više animacija uz već prisutne boje radi dodatnog naglašavanja govornog zapisa; (8) dodavanjem zvučnih zapisa; (9) smanjenjem količine sadržaja po slajdovima; (12) paralelnim radom u Logo programu (umjesto rješavanja zadataka na papiru) ili izravnim isprobavanjem u Logo programu kroz poveznice; (13) uvođenjem ovog programa u redovitu nastavu; (14) „*upotrebom programa u drugim predmetima i s drugim sadržajima kako bi ih učinili zanimljivijima*“; (15) prilagodbom sadržaja prema predznanju učenika i reduciranjem količine teksta na određenim slajdovima (posebno za korisnike s nižom razinom predznanja); (16) upotrebom programa u svrhu ponavljanja, a ne za učenje novog sadržaja; (17) čineći program „*opće dostupnim i otvorenim za svaku temu*“; (18) dodavanjem usmenih izlaganja profesora; (19) fleksibilnom prilagodbom vremena.

5.9 Diskusija hipoteza

Prva hipoteza se odnosi na sveukupnu procjenu eksperimentalnog programa kroz sva tri tjedna istraživanja. Druga hipoteza procjenjuje se kroz analizu prvog i drugog tjedna eksperimentalnog programa, a treća hipoteza se odnosi na treći tjedan eksperimentalnog programa.

(H2) Studenti koji koriste multimedijску instruktivnu poruku s primjenom načela raščlanjivanja postižu bolje rezultate pri rješavanju niza zadataka objektivnog tipa u zapamćivanju i razumijevanju sadržaja za koji je izlazna vrijednost geometrijska vrsta podataka, nego studenti koji koriste poruku bez primjene načela raščlanjivanja.

Prvi tjedan istraživanja (tablica 38) pokazuje kako nisu pronađene statistički značajne razlike između kontrolne ($M_{\text{zapamćivanje}}=3,96$, $SD_{\text{zapamćivanje}}=1,480$; $M_{\text{razumijevanje}}=3,66$, $SD_{\text{razumijevanje}}=0,826$) i eksperimentalne ($M_{\text{zapamćivanje}}=3,56$, $SD_{\text{zapamćivanje}}=1,769$; $M_{\text{razumijevanje}}=3,40$, $SD_{\text{razumijevanje}}=1,064$) skupine ispitanika u pogledu rješavanja zadataka

zapamćivanja i razumijevanja sadržaja. Razlog tome može se pronaći u sadržaju poruke i niskoj razini matematičkog i logičkog predznanja.

Sadržaj poruke prvog tjedna istraživanja obuhvaćao je temeljne programske koncepte. Uloga načela raščlanjivanja, realiziranog kombinacijom načela signalizacije, animacije i interaktivnosti, trebala je pomoći ispitanicima u odabiru sadržajno relevantnih dijelova MIPL-a, te organizaciji vizualnih predodžbi (na temelju simultanog prikaza pojedinačne naredbe i pripadajućeg pomaka kornjače unutar okvira animacije iscrtavanja kvadrata, trokuta i šesterokuta) i zvučnih predodžbi (na temelju govornog isticanja naredbi) u koherentne mentalne strukture ili mentalne modele. Uspješna izgradnja referentnih veza između vizualnih i zvučnih predodžbi omogućuje formiranje logičkih veza između pojedinačnih naredbi programa (identifikacija uzročno-posljedičnog slijeda radnji u strukturi programskoga kôda) i formiranje odgovarajućeg mentalnog modela programskog koncepta. Dakle, svrha instrukcijske računalne animacije bila je usmjeriti pažnju ispitanika na promjene grafičkog pokazivača kornjače u skladu sa zadanim parametrima naredbi kako bi se kroz proces mentalne simulacije (vještina praćenja tijekom izvođenja programa kod iscrtavanja geometrijskih likova kvadrat, trokut, šesterokut, te niza likova upotrebom REPEAT petlje) izgradio odgovarajući dinamični mentalni model (Hegarty, M., 1992) programskog koncepta. Međutim, otežavajući čimbenik predstavljala je niska razina matematičkog predznanja ispitanika u poznavanju geometrijskih kutova, što je sprječavalo proces kognitivnog povezivanja parametara programskih naredbi (kutovi rotacije kornjače) s odgovarajućim vizualnim prikazima pomaka kornjače (prvi, drugi i treći zadatak), a samim time i nemogućnost adekvatnog praćenja izvođenja, čitanja i pisanja programa (četvrti i peti zadatak). Praćenje izvođenja programa predstavlja svojevrsnu mentalnu simulaciju (Sorva, J., 2012), što je u ovom slučaju zahtijevalo određenu razinu geometrijskog znanja da bi se uspješno formirao mentalni model programa (naredbi i struktura). Pretpostavka je da su ispitanici veći dio kognitivnog kapaciteta uložili u razumijevanje geometrijskog dijela sadržaja MIPL-a s matematičkog aspekta, zbog čega je primarna uloga MIPL-a za usvajanjem programskih koncepata postala sekundarna, te nije bilo moguće realno procijeniti utjecaj načela raščlanjivanja u stjecanju programerskog znanja.

Nadalje, primjenom načela raščlanjivanja, nad strukturom sadržaja MIPL-a u eksperimentalnoj skupini, nastojalo se reducirati kognitivne zahtjeve u programerskom dijelu sadržaja. Međutim, s obzirom da je sadržaj poruke prvog tjedna istraživanja obuhvaćao temeljne programske koncepte postoji mogućnost da je jedan dio ispitanika bio sposoban mentalno simulirati prikazane koncepte uz određeni napor, što je izravno utjecalo na

smanjenje sadržajno relevantnog kognitivnog opterećenja. Samim time, načelo raščlanjivanja pokazalo se redundantnim faktorom MIPL-a (Mautone, P. D. i Mayer, R. E., 2001; de Koning, B. B. i sur., 2007), a animacija beskorisnim i moguće štetnim čimbenikom u procesu učenja (engl. *inhibiting function*), (Schnotz, W. i Rasch, T., 2005).

Drugi tjedan istraživanja (tablica 42) pokazuje kako nisu pronađene statistički značajne razlike između kontrolne ($M_{\text{zapamćivanje}}=6,10$, $SD_{\text{zapamćivanje}}=0,652$; $M_{\text{razumijevanje}}=0,82$, $SD_{\text{razumijevanje}}=0,634$) i eksperimentalne ($M_{\text{zapamćivanje}}=5,80$, $SD_{\text{zapamćivanje}}=1,135$; $M_{\text{razumijevanje}}=0,79$, $SD_{\text{razumijevanje}}=0,645$) skupine u pogledu rješavanja zadataka zapamćivanja i razumijevanja sadržaja. Razlog tome može se pronaći, kao i tijekom prvog tjedna istraživanja, u sadržaju poruke i niskoj razini matematičkog i logičkog predznanja. Pri tome, drugi tjedan istraživanja obuhvaćao je osnovne, ali složenije programske koncepte gdje je niska razina geometrijskog predznanja u poznavanju kutova, likova (paralelogram, romb) i ploha (kocka) uvelike otežala proces praćenja izvođenja i čitanja procedura (prvi, drugi i četvrti zadatak), te pisanja procedura (treći i peti zadatak). Zbog toga nije bilo moguće adekvatno provjeriti usvojeno znanje određenog programskog koncepta odnosno izmjeriti učinak načela raščlanjivanja na zapamćivanje i razumijevanje sadržaja. Također, postoji mogućnost da se dogodio obrnuti učinak u primjeni načela raščlanjivanja nad programerskim dijelom sadržaja, koje se u ovom slučaju zbog niske razine geometrijskog predznanja pokazalo štetnim čimbenikom u procesu učenja, jer je dodatno opterećivalo kapacitet radne memorije ispitanika. U pogledu ispitivanja razlika prema pripadnosti studijskoj godini na zadacima zapamćivanja dobivene su statistički značajne razlike između studenata treće i pete godine ($r=0,276$), te između studenata četvrte i pete godine ($r=0,290$). U oba slučaja studenti pete godine ostvarili su niži rezultat u odnosu na treću i četvrtu godinu, a između studenata treće i četvrte godine nije bilo statistički značajnih razlika. Ovakvi rezultati mogu se pripisati različitom predznanju ispitanika, gdje su se studenti treće godine mogli osloniti na svoje osnovno i srednjoškolsko obrazovanje, studenti četvrte godine na osnovno programersko znanje koje su paralelno sa trajanjem eksperimentalnog programa stjecali na kolegiju „Programiranje“, a studenti pete godine na postojeće mentalne modele programskih koncepata formiranih u sklopu kolegija „Programiranje“, te metodičku naobrazbu iz matematičkih kolegija. Očigledno je predznanje ispitanika treće i četvrte godine bilo na višoj razini od studenata pete godine, koji iako su prošli odgovarajuću programersku i matematičku naobrazbu na fakultetu, nisu uspjeli uz pomoć MIPL-a nadoknaditi nedostatke u svom znanju.

Iz sveukupnih rezultata prvog i drugog tjedna istraživanja može se zaključiti kako dodatno primijenjeno **načelo raščlanjivanja nije pridonijelo boljem zapamćivanju i**

razumijevanju sadržaja multimedijske instruktivne poruke, za koji je izlazna vrijednost geometrijska vrsta podataka, čime nije potvrđena druga hipoteza (H2).

(H3) Studenti koji koriste multimedijску instruktivnu poruku s primjenom načela raščlanjivanja postižu bolje rezultate pri rješavanju niza zadataka objektivnog tipa u zapamćivanju i razumijevanju sadržaja za koji je izlazna vrijednost negeometrijska vrsta podataka, nego studenti koji koriste poruku bez primjene načela raščlanjivanja.

Treći tjedan istraživanja (tablica 49) pokazuje da nisu pronađene statistički značajne razlike između kontrolne ($M_{\text{zapamćivanje}}=10,78$, $SD_{\text{zapamćivanje}}=2,073$; $M_{\text{razumijevanje}}=3,83$, $SD_{\text{razumijevanje}}=1,667$) i eksperimentalne ($M_{\text{zapamćivanje}}=10,80$, $SD_{\text{zapamćivanje}}=1,539$; $M_{\text{razumijevanje}}=3,65$, $SD_{\text{razumijevanje}}=1,861$) skupine u pogledu rješavanja zadataka zapamćivanja i razumijevanja sadržaja. Zbog evidentirane subjektivne procjene niske razine programerskog predznanja na predtestu, na prva dva zadatka nije bilo primijenjeno načelo raščlanjivanja u eksperimentalnoj skupini kako bi svi ispitanici primili istu multimedijску poruku za formiranje mentalnih modela MAKE naredbe i osnovnih naredbi za rad s riječima i listama. Sadržaj poruke na kojom je primijenjeno načelo raščlanjivanja (treći, četvrti, peti i šesti zadatak) obuhvaćao je programske strukture WHILE i FOR petlji i rad algoritma, te vještine konkretnog praćenja izvođenja, čitanja i pisanja programskog kôda. Praćenje izvođenja programskog kôda, kao i tijekom prva dva tjedna, podrazumijeva jednu vrstu mentalne simulacije programa, ali u ovom slučaju to obuhvaća praćenje promjena stanja varijabli (za zadane početne vrijednosti) i načina rada programskih struktura (WHILE i FOR petlje), što zahtjeva upotrebu održivih mentalnih modela koncepta varijable, osnovnih naredbi za rad s riječima i listama i MAKE naredbe (prvi i drugi zadatak). Kako je u odnosu na sadržaj cijelog eksperimentalnog programa, u trećem tjednu utvrđena vrlo niska rješivost zadataka (3, 4, 5, 6), (tablica 49) i visoka procjena mentalnog napora (tablica 52), pokazalo se da ispitanici nisu bili sposobni pratiti izvođenje programskog kôda, što može biti rezultat apstraktne naravi sadržaja poruke odnosno niske razine logičkog predznanja, neuspješnog stvaranja mentalnih modela u prva dva zadatka ili upotrebe već postojećih mentalnih modela programskih konceptata stečenih u osnovnom, srednjoškolskom i fakultetskom obrazovanju. Ako su pri tome postojeći mentalni modeli razvijeni na temelju miskoncepcija ispitanici posjeduju netočno i necjelovito razumijevanje programskih konceptata, što rezultira otežanim praćenjem izvođenja programa, neispravnim čitanjem ili objašnjavanjem programa, te pisanjem neproduktivnih i nefunkcionalnih programa (Sorva, J., 2012). Koncept varijable, izjava

pridruživanja, te WHILE i FOR petlje ubrajaju se među najproblematičnije programske koncepte (Dehnadi, S. i Bornat, R., 2006; Kaczmarczyk, L. C. i sur., 2010; Sorva, J., 2012, str. 359-368). Iako identificiranje miskoncepcija i neodrživih mentalnih modela programskih koncepata izlazi izvan okvira eksperimentalnog programa, moguće ih je uzeti u obzir kao jedan od čimbenika za neuspješnu primjenu načela raščlanjivanja na zapamćivanje i razumijevanje sadržaja.

Iz sveukupnih rezultata trećeg tjedna istraživanja može se zaključiti da dodatno primijenjeno **načelo raščlanjivanja nije pridonijelo boljem zapamćivanju i razumijevanju sadržaja multimedijske instruktivne poruke, za koji je izlazna vrijednost negeometrijska vrsta podataka, čime nije potvrđena treća hipoteza (H3).**

(H1) Studenti koji koriste multimedijску instruktivnu poruku s primjenom načela raščlanjivanja postižu bolje rezultate pri rješavanju niza zadataka objektivnog tipa u zapamćivanju i razumijevanju sadržaja, nego studenti koji koriste poruku bez primjene načela raščlanjivanja.

Iz sveukupnih rezultata svih triju tjedana (tablice 38, 42 i 49) može se zaključiti da **načelo raščlanjivanja nije pridonijelo zapamćivanju i razumijevanju sadržaja multimedijske instruktivne poruke, čime nije potvrđena prva hipoteza (H1).**

6 ZAKLJUČAK

Programski jezik Logo je viši programski jezik treće generacije autora Seymour Paperta, Wally Feurzeiga i Danny Bobrowa, razvijen 1966. godine (Papert, S., 1983). Konstruktivistička priroda Logo jezika ukorijenjena je u kognitivnoj teoriji učenja, a temelji se na načelu „kornjače“, odnosno pomoćnog objekta u formi grafičkog pokazivača za obavljanje osnovnih operacija kretanja definiranih parametrima programskih naredbi. Sinergija izvođenja apstraktnih naredbi i grafičkih pomaka kornjače pokazala se kao odgovarajući konstruktivistički alat za razvoj kritičnog i logičnog načina razmišljanja u djece i mladih (Papert, S., 1993; Lee, M. O. C., 1991), prilikom rješavanja različitih zadataka problemskog tipa, kao što su crtanje niza geometrijskih likova, rad s različitim tipovima podataka, oblikovanje 2D i 3D animacije i drugo. Većina istraživanja Logo jezika u svijetu bila je usmjerena na razvoj kognitivnih sposobnosti kod učenika mlađeg školskog uzrasta. Malo je istraživanja provedeno sa studentima (Lee, M. O. C., 1991; Fay, A. L. i Mayer, R. E., 1994), a još manje s budućim učiteljima informatike.

Cilj ovom istraživanju bio je ispitati učinkovitost *multimedijske instruktivne poruke za programski jezik Logo* (MIPL), kod studenata razredne nastave, budućih učitelja informatike. Radi ispitivanja razlika u zapamćivanju i razumijevanju sadržaja, razvijen je obrazovni sadržaj kojeg čine osnovni pojmovi odabranih nastavnih tema programskog jezika Logo, u formi multimedijske instruktivne poruke utemeljene na osam osnovnih načela (*načelo multimedijske, načelo prostorne povezanosti, načelo vremenske usklađenosti, načelo koherentnosti, načelo modaliteta, načelo zalihosnosti, načelo individualnih razlika, načelo signalizacije*) i jednim naprednim načelom (*načelo animacije i interaktivnosti*) kognitivne teorije multimedijskog usvajanja znanja (kontrolna skupina), te s nadopunjenim načelom raščlanjivanja *modela kognitivnog procesa multimodalnog razumijevanja* (eksperimentalna skupina). U istraživanju su sudjelovali studenti treće, četvrte i pete godine studija Učiteljskog fakulteta Sveučilišta u Zagrebu. Istraživanje je provedeno na ciljanom uzorku od 98 ispitanika razredne nastave, modula informatike, u Zagrebu (45) i Čakovcu (53). Od 45 ispitanika u Zagrebu njih 22 je prema abecednom redu dodijeljeno kontrolnoj skupini (MIPL bez primjene načela raščlanjivanja), a 23 iz ostatka abecednog popisa studenata eksperimentalnoj skupini (MIPL s primjenom načela raščlanjivanja). Od 53 ispitanika u Čakovcu njih 26 je prema abecednom redu dodijeljeno kontrolnoj skupini, a 27 iz ostatka abecednog popisa studenata eksperimentalnoj skupini. Sveukupno u kontrolnoj skupini bilo je 48 ispitanika, a u eksperimentalnoj 50 ispitanika.

U doktorskoj disertaciji postavljene su tri hipoteze:

(H1) Studenti koji koriste multimedijску instruktivnu poruku s primjenom načela raščlanjivanja postižu bolje rezultate pri rješavanju niza zadataka objektivnog tipa u zapamćivanju i razumijevanju sadržaja, nego studenti koji koriste poruku bez primjene načela raščlanjivanja.

(H2) Studenti koji koriste multimedijску instruktivnu poruku s primjenom načela raščlanjivanja postižu bolje rezultate pri rješavanju niza zadataka objektivnog tipa u zapamćivanju i razumijevanju sadržaja za koji je izlazna vrijednost geometrijska vrsta podataka, nego studenti koji koriste poruku bez primjene načela raščlanjivanja.

(H3) Studenti koji koriste multimedijскую instruktivnu poruku s primjenom načela raščlanjivanja postižu bolje rezultate pri rješavanju niza zadataka objektivnog tipa u zapamćivanju i razumijevanju sadržaja za koji je izlazna vrijednost negeometrijska vrsta podataka, nego studenti koji koriste poruku bez primjene načela raščlanjivanja.

U sva tri tjedna istraživanja nisu pronađene statistički značajne razlike između kontrolne i eksperimentalne skupine ispitanika u pogledu rješavanja zadataka zapamćivanja i razumijevanja sadržaja čime nije potvrđena prva hipoteza (H1).

U prva dva tjedna istraživanja studenti pete godine ostvarili su niži rezultat u odnosu na treću i četvrtu godinu na zadacima zapamćivanja sadržaja, a između studenata treće i četvrte godine nije bilo statistički značajnih razlika. Može se zaključiti da je razina matematičkog i logičkog predznanja u poznavanju geometrijskih kutova, likova (paralelogram, romb) i ploha (kocka) ispitanika treće i četvrte godine bila na višoj razini od studenata pete godine. Niska razina navedenog predznanja otežala je proces kognitivnog povezivanja parametara programskih naredbi (pomaci i kutovi rotacije) s odgovarajućim vizualnim prikazima kretanja kornjače, a samim time i nemogućnost adekvatnog praćenja izvođenja programa, te čitanja i pisanja programa. Praćenje izvođenja programa u formi mentalne simulacije (Sorva, J., 2012) zahtijevalo je određenu razinu geometrijskog predznanja kako bi se uspješno formirao mentalni model prikazanog programskog koncepta (naredbi i struktura). Međutim, pretpostavka je da su ispitanici veći dio kognitivnog kapaciteta uložili u razumijevanje geometrijskog dijela sadržaja MIPL-a, umjesto programskih koncepata, zbog čega nije bilo moguće adekvatno provjeriti učinak načela raščlanjivanja na zapamćivanje i razumijevanje sadržaja odnosno provjeriti usvojeno programersko znanje. Također, postoji mogućnost da se primijenjeno načelo raščlanjivanja nad programerskim dijelom sadržaja u eksperimentalnoj skupini pokazalo štetnim čimbenikom u procesu učenja, jer je dodatno opterećivalo kapacitet radne memorije ispitanika, odnosno predstavljalo visoko esencijalno opterećenje zbog niske

razine geometrijskog predznanja. To potvrđuju rezultati visoke razine mentalnog napora subjektivno procijenjenog od strane svih studenata ($M_I=4,26$, $M_{II}=4,70$, $M_{III}=5,43$).

U trećem tjednu istraživanja kod svih ispitanika kontrolne i eksperimentalne skupine utvrđena je vrlo niska rješivost zadataka i vrlo visoka procjena mentalnog napora, što se pripisuje niskoj razini logičkog predznanja (apstraktan sadržaj poruke), neuspješnom formiranju mentalnih modela u prva dva zadatka ili upotrebe već postojećih neodrživih mentalnih modela programskih koncepata stečenih u ranijem obrazovanju i razvijenih na temelju miskoncepcija. To je rezultiralo otežanom praćenju izvođenja programa, kao što potvrđuju i istraživanja drugih autora (Kaczmarczyk, L. C. i sur., 2010, Simon, 2011), neispravnom čitanju programa, te pisanju neproduktivnih i nefunkcionalnih programa, do kojih spoznaja su došli i drugi istraživači (Sorva, J., 2012). Sadržaj MIPL-a trećeg tjedna istraživanja obuhvaćao je programske koncepte: varijabla, MAKE naredba za pridruživanje numeričke vrijednosti ili znakovnog niza varijabli i programske strukture WHILE i FOR petlji. Kako se ti koncepti ubrajaju u najproblematičnije (Dehnadi, S. i Bornat, R., 2006; Kaczmarczyk, L. C. i sur., 2010; Sorva, J., 2012, str. 359-368), velika je mogućnost da su studenti posjedovali neodržive ili nikakve mentalne modele iz ranijeg obrazovanja.

Sveukupni rezultati ovog istraživanja pokazali su da dodatno primijenjeno načelo raščlanjivanja nije pridonijelo boljem zapamćivanju i razumijevanju sadržaja multimedijske instruktivne poruke, za geometrijsku (prvi i drugi tjedan) i negeometrijsku (treći tjedan) izlaznu vrijednost podataka, čime nisu potvrđene druga (H2) i treća (H3) hipoteza.

Odgovori ispitanika na kategorijalna pitanja pokazali su kako se 91,8% njih nikada nije susrelo s ovakvom vrstom multimedijskog sadržaja za učenje programiranja, a 70% njih je izjavilo da im se sviđa ovakav način učenja programiranja. Prema odgovorima ispitanika kontrolne i eksperimentalne skupine ovakav način učenja programiranja im se svidio jer je drukčiji, koristan, nov, motivirajući, zanimljiv po sadržaju i načinu učenja, te nije dosadan i suhoparan. Istakli su njima važne elemente MIPL-a: (1) digitalni način prikaza informacija, naspram klasičnog predavanja, zbog vizualnih i zvučnih prikaza popraćenih govorom; (2) mogućnost određivanja vlastitog tempa učenja pomoću elementa interaktivnosti sadržaja; (3) *postupni način objašnjavanja – 'korak po korak'*; (4) detaljna analiza svakog postupka i zadatka; (5) *mogućnost lakšeg predočavanja i memoriranja* informacija; (6) pregledni prikaz teorijskog dijela sadržaja potkrijepljenog dodatnim objašnjenjima kroz govor i konkretnim primjerima sa simultanim prikazom rezultata; (7) mogućnost vlastite provjere znanja kroz samostalno rješavanje zadataka; (8) dovoljno vremena na raspolaganju za usvajanje novih

koncepta; (9) sadržajna povezanost i lakoća vizualne percepcije; (10) jednostavni pristup sadržaju, te podrška tradicionalnom poučavanju i mogućnost upotrebe sadržaja izvan nastavnih aktivnosti (kod kuće).

Prema odgovorima ispitanika kontrolne i eksperimentalne skupine unaprjeđenje sadržaja MIPL-a može se ostvariti: (1) jasnijim i opširnijim uputama te dodavanjem više definicija u formi teksta i dodatnih sadržaja tijekom objašnjavanja zadataka zbog moguće nejasnoće gradiva (pojednostavljenja naredbi i zadataka); (2) dodavanjem računalnih zadataka, kratkih provjera znanja i primjera za vježbanje, tijekom procesa učenja s povratnom informacijom o postignućima; (3) dodavanjem slika i animacija koje bi olakšale vizualizaciju i kretanje kornjače (kontrolna skupina), te dodatno naglasile govorne zapise (eksperimentalna skupina); (4) uvođenjem video zapisa s prikazom objašnjenja koncepta u formi „*korak po korak*“; (5) uvođenjem usmenih izlaganja profesora za razumijevanje principa rješavanja zadataka.

Veći broj ispitanika u obje skupine naglasio je da multimedijски sadržaj, bez obzira na sve vizualne i zvučne prednosti, ne može zamijeniti usmeno izlaganje i vodstvo profesora, što su potvrdili i drugi istraživači (Rias, R. M. i Zaman, H. B., 2013). Međutim, kako obrazovne navike studenata priječe upotrebu MIPL-a za učenje programiranja, svi ispitanici ističu važnost „*žive riječi*“ profesora.

U odgovorima ispitanika eksperimentalne skupine sugerira se smanjenje količine sadržaja i teksta po slajdovima, omogućavanje fleksibilne prilagodbe vremena, te većeg broja sati nastave za učenje putem MIPL-a, što se može pripisati kognitivnom opterećenju nastalom uslijed primijenjenog načela raščlanjivanja.

Ispitanici kontrolne skupine predvidjeli su poboljšanje ovog programa uvođenjem *vodstva – virtualnog mentora*, što odgovara načelu virtualnog predavača prema KTMUZ-u (Mayer, R. E., 2009, prema Kassim, H., 2011; Mayer, R. E. i Alexander, P. A., 2011; Mayer, R. E., 2014c, prema Benassi, V. A., Overson, C. E. i Hakala, C. M., 2014). Iako je načelo individualnih razlika primijenjeno u dva najvažnija aspekta: nisko predznanje korisnika u programerskom dijelu sadržaja MIPL-a i visoke prostorne sposobnosti studenata razredne nastave, eksperimentalnim programom nisu obuhvaćeni kognitivni stil i stil učenja ispitanika, jer je to izlazilo izvan okvira ovog istraživanja. Načelo virtualnog predavača je napredno načelo KTMUZ-a i može se pripisati stilu učenja.

U oblikovanju sadržaja MIPL-a za eksperimentalnu skupinu nisu u cijelosti primijenjena sva načela oblikovanja instrukcijske animacije: *načelo dosljednosti*, *načelo razumijevanja*, *načelo interaktivnosti*, *načelo vođenja pažnje* i *načelo fleksibilnosti*

(Bétrancourt, M., 2005, prema Mayer, R. E., 2005, str. 294-295). Načelo fleksibilnosti ističe važnost individualnih razlika osobito razine predznanja, što se očituje kao mogućnost uključivanja i isključivanja animacijskih prikaza odnosno zamjene animacije statičnim slikovnim prikazima. Kontrolna skupina je za određeni programerski sadržaj MIPL-a primila statične, a eksperimentalna pokretne prikaze (animacija), ali obje mogućnosti nisu bile podržane niti u jednoj skupini, jer se provjeravala učinkovitost načela raščlanjivanja, jednim dijelom realiziranog instrukcijskim animacijama geometrijskog sadržaja. Iako se može uočiti da je jednom broju ispitanika kontrolne skupine nedostajala animacija kretanja kornjače, to se nije pokazalo značajnijim faktorom u unaprjeđenju zapamćivanja i razumijevanja sadržaja u eksperimentalnoj skupini (vidi tablice 38 i 42), što može biti posljedica niske razine geometrijskog predznanja ili nedostatak instrukcijskih animacija u sadržaju poruke, kako su naveli ispitanici. U odgovorima obje skupine naglašena je potreba za dodavanjem animacija, ali u različite svrhe. U kontrolnoj skupini ističe se važnost vizualizacije kretanja kornjače upotrebom animacije, a u eksperimentalnoj skupini važnost dodavanja animacije radi naglašavanja govornog zapisa.

Uz statičnu i pokretnu sliku ispitanici dodatno ističu potrebu za većim stupnjem interakcije sa sadržajem MIPL-a: (1) povratne informacije o postignućima; (2) mogućnosti promjene vrijednosti varijabli; (3) periodične provjere znanja u procesu učenja. Načelo interaktivnosti MIPL-a uključivalo je samo kontrolu brzine i smjera izmjene niza okvira animacije, ali ne i djelovanje na događaje unutar okvira promjenom određenih parametara od strane ispitanika na temelju čega bi animacija prešla u simulaciju i otvorila mogućnost učinkovitijeg predviđanja rada programa kroz proces mentalne simulacije, što ističu brojni autori (Narayanan, N. H. i Hegarty, M., 2002). Ispitanici su predvidjeli upravo ono što su brojni istraživači potvrdili, prema kojima se stupanj aktivnog angažmana korisnika u susretu sa vizualnim sadržajem općenito pokazao važnijim od načina prikaza sadržaja ili reprezentacijskog aspekta vizualizacije (Naps, T. L. i sur., 2002; Rapp, D. N., 2005; Koning, B. B. i sur., 2011). Dakle, kako je učinkovitost primjene vizualizacije povezana sa stupnjem kognitivnog angažmana u procese relevantne za smisleno usvajanje znanja (Mayer, R. E., 2008), postoji mogućnost da bi nadogradnja načela raščlanjivanja sa cjelovitim animacijskim načelima fleksibilnosti i interakcije unaprijedila proces učenja, bez obzira na nisku razinu geometrijskog predznanja. Samim time, povećala bi se količina sadržaja na slajdovima i kognitivno opterećenje radne memorije ispitanika, jer bi poruka sadržavala mogućnost uključivanja i isključivanja statičnih i pokretnih prikaza geometrijskog dijela sadržaja, a programerski dio mogućnost izmjene tijekom izvođenja programskog kôda u skladu s ulaznim

vrijednostima varijabli ili parametrima naredbi. Kognitivno opterećenje reguliralo bi se elementima interaktivnosti u programu, a pregledavanje sadržaja MIPL-a zahtijevalo bi fleksibilni vremenski pristup, odnosno služilo kao kognitivno pomoćno sredstvo za samostalno učenje programiranja, sa ili bez paralelnog rada u Logo programu, ovisno o stilu učenja ispitanika.

Dio ispitanika je sugerirao prethodno učenje programiranja u Logo jeziku prije susreta s multimedijском porukom, a dio paralelni rad u Logo programu. U prvom slučaju, *prethodnog učenja* u Logo programu, gubi se svrha MIPL-a kao konceptualnog modela za usvajanje osnovnih pojmova Logo jezika i logičkog načina razmišljanja u primjeni programerskih koncepata. Prema KTMUZ-u, MIPL slijedi načelo pripremne obuke (Fay, A. L. i Mayer, R. E., 1994, prema Mayer, R. E., 2004), gdje ispitanici prvo primaju multimedijску instruktivnu poruku o osnovnim konceptima Logo jezika, a potom programiraju u Logo jeziku, odnosno uče nastavnom metodom samootkrivanja (Mayer, R. E., 2004). Takav „slijedni“ pristup poučavanja pokazao se učinkovitim za razvoj vještina pisanja računalnih programa (Fay, A. L. i Mayer, R. E., 1994, prema Mayer, R. E., 2004), što obuhvaća vještine praćenja izvođenja i čitanja programskog kôda. U drugom slučaju, *paralelnog rada* u Logo programu, moguće je pomiriti oba pristupa, instruktivno vođenje (engl. *guided instruction*) MIPL-a i istraživački pristup učenja (engl. *self-discovering learning*), što se u mnogim istraživanjima pokazalo učinkovitim pristupom poučavanja programskog jezika Logo (Lee, M. O. C., 1991; Feurzeig, W., 2010).

Rezultati provedenog istraživanja (nepotvrđene hipoteze istraživanja) sugeriraju da je u budućim istraživanjima važno predtestom provjeriti predznanje ispitanika, jer je u ovom istraživanju predviđena očekivana razina znanja geometrije i razvijenosti prostornih sposobnosti, što kod ispitanika nije bio slučaj. Njihova nedostatna predznanja utjecala su na nemogućnost provjere načela raščlanjivanja na zapamćivanje i razumijevanje sadržaja. Mogući razlozi mogu se pronaći u univerzalnim problemima s kojima se studenti susreću u procesu programiranja: niska razina matematičkog i logičkog predznanja (Byrne, P. i Lyons, G., 2001; Caspersen, M. E., 2007), te sposobnost logičkog razmišljanja i razvoj održivih mentalnih modela (Bergin, S. i Reilly, R., 2006, prema Caspersen, M. E., 2007, str. 56-58).

Navedene probleme matematičkog, logičkog i programerskog predznanja nije moguće nadoknaditi jednim eksperimentalnim programom, uzevši u obzir kako su ove generacije studenata primljene na fakultet s položenom razinom B iz predmeta matematike na državnoj maturi. Također, mogući razlog neuspješne primjene MIPL-a je u prekasnom uvođenju kolegija početnog programiranja na četvrtoj i petoj godini studija Razredne nastave, radi

praćenja sadržaja metodičkih kolegija na modulu informatike, dok su prve tri godine orijentirane na osnove informatike, građu računala, informacijske sustave, računalne mreže, baze podataka, korištenje računala i Interneta. Kako u prve tri godine studenti nisu kontinuirano fokusirani na razvoj programerskih vještina, rezultati ovog istraživanja su alarmantni pokazatelj da su izmjene programa modula informatike više nego potrebne. Međutim, iako se program može mijenjati kako bi se prilagodio kognitivnom razvoju novih generacija studenata, to nije konačno niti prihvatljivo rješenje. Izmjene i modernizacija predmeta informatike u osnovnim i srednjim školama kroz nove i suvremenije nastavne metode učenja i poučavanja su temeljni problem i potreba današnjeg vremena (Markučić, Z. i sur., 2012). U osnovnim školama informatika ulazi u kategoriju izbornih predmeta i samo je određeni dio sadržaja predmeta posvećen programiranju. U srednjim školama učenici uče informatiku u prvom ili drugom razredu, osim u prirodoslovno-matematičkim gimnazijama gdje se informatika sluša u sva četiri razreda. Ako se uzme u obzir kako je potrebno oko 10 godina iskustva da programer početnik postane programer stručnjak (Winslow, L. E., 1996, prema Robins, A., Rountree, J. i Rountree, N., 2003), budući učitelji u fazi obrazovanja mogu se svrstati u kategoriju naprednog programera početnika ili kompetentnog programera (Dreyfus, H. i Dreyfus, S., 1986, prema Robins, A., Rountree, J. i Rountree, N., 2003), ovisno o predznanju koje unose u fakultetsko okruženje. Međutim, po završetku petogodišnjeg studija oni bi trebali steći znanja i vještine na razini kompetentnih programera s planom cjeloživotnog obrazovanja kako bi dugogodišnjom praksom i iskustvom stekli titulu vještog programera i metodičara informatike.

Sve navedeno upućuje na praktični doprinos ovog doktorskog istraživanja, a njegov znanstveni doprinos sastoji se u oblikovanju i razvoju *multimedijske instruktivne poruke za programski jezik Logo* (MIPL), koja objedinjuje kognitivni i programersko-metodički aspekt. Ovo je prvi rad koji prikazuje razvoj i primjenu *multimedijske instruktivne poruke* kao kognitivno pomoćno sredstvo za usvajanje osnovnih pojmova programskog jezika Logo, utemeljene na empirijski utvrđenim načelima *kognitivne teorije multimedijskog usvajanja znanja* (Mayer, R. E., 2001, 2005, 2014a) i dodatnom *načelu raščlanjivanja* iz područja algoritama i strukture podataka, definiranom prema *modelu kognitivnog procesa multimodalnog razumijevanja* (Narayanan, N. H. i Hegarty, M., 2002). Programersko-metodički aspekt MIPL-a služi samorefleksiji budućih učitelja u njihovom logičkom, matematičkom i informatičkom znanju za teme koje će provoditi u nastavi informatike.

7 LITERATURA

1. Ackermann, E. (2009). Piaget's Constructivism, Papert's Constructionism: What's the difference? Dostupno na: <http://www.sylvia stipich.com/wp-content/uploads/2015/04/Coursera-Piaget--Papert.pdf> [18.06.2017.]
2. Agalianos, A., Whitty, G., Noss, R. (2006). The Social Shaping of Logo. *Social Studies of Science*, 36 (2), 241-267.
3. Ainsworth, S. E., Van Labeke. N. (2004). Multiple forms of dynamic representation. *Learning and Instruction*, 14 (3), 241-255.
4. Amadiou, F., Mariné, C., Laimay, C. (2011). The attention-guiding effect and cognitive load in the comprehension of animations. *Computers in Human Behavior*, 27 (1), 36-40.
5. Anderson, L. W. (Ed.), Krathwohl, D. R. (Ed.), Airasian, P. W., Cruikshank, K. A., Mayer, R. E., Pintrich, P. R., Raths, J., Wittrock, M. C. (2001). *A taxonomy for learning, teaching, and assessing: A revision of Bloom's Taxonomy of Educational Objectives (Complete edition)*. New York: Longman.
6. Anglin, G. J., Vaez, H., Cunningham, K. L. (2004). Visual representations and learning: The role of static and animated graphics. In *Handbook of research for educational communications and technology (2nd Edition, 865–916)*: Mahwah, NJ, Lawrence Erlbaum Associates.
7. Artino, A. R., Jr. (2008). Cognitive load theory and the role of learner experience: An abbreviated review for educational practitioners. *AACE Journal*, 16 (4), 425-439.
8. Atkinson, R. K. (2002). Optimizing learning from examples using animated pedagogical agents. *Journal of Educational Psychology*, 94, 416–427.
9. Au, W. K. (1992). *LOGO: instructional methods and problem solving*. A thesis presented in partial fulfilment of the requirements for the degree of Doctor of Philosophy in Education, Faculty of Education, Massey University, Palmerston North, New Zealand. Dostupno na: <http://mro.massey.ac.nz/handle/10179/4122> [18.06.2017.]
10. Austin Stalcup, K. A. (2005). *Multimedia Learning: Cognitive Individual Differences And Display Design Techniques Predict Transfer Learning With Multimedia Learning Modules*. Doctoral Dissertation in Experimental Psychology. Graduate Faculty of Texas Tech University. Dostupno na: <https://pdfs.semanticscholar.org/7689/c82e989db436491147d952cf050be674f0f2.pdf> [02.11.2017.]

11. Ayres, P., Marcus, N., Chan, C., Qian, B. (2009). Learning hand manipulative tasks: When instructional animations are superior to equivalent static representations. *Computers in Human Behavior*, 25, 348-353.
12. Ayres, P., Paas, F. (2007). Making instructional animations more effective: A cognitive load approach. *Applied Cognitive Psychology*, 21(6), 811 – 820.
13. Baddeley, A. (1992). Working memory. *Science, New Series*, 255 (5044), 556-559.
14. Baddeley, A. D. (1986). *Working memory*. Oxford, England. Oxford University Press.
15. Baddeley, A. D. (1999). *Human memory*. Boston. Allyn & Bacon.
16. Baddeley, A. D. (2003). *Human Memory: Theory and Practice*. New York: Psychology Press, Revised Edition.
17. Baddeley, A., Eysenck, M. W., Anderson, M. C. (2009). *Memory*. Hove: Psychology Press. Dostupno na: <http://tandfbis.s3.amazonaws.com/rt-media/pp/common/sample-chapters/9781848720015.pdf> [17.10.2017.]
18. Baldwin, L. P., Kuljis, J. (2000). Visualisation Techniques for Learning and Teaching Programming. *Journal of Computing and Information Technology*, 8 (4), 285–291. Dostupno na: <http://cit.fer.hr/index.php/CIT/article/view/1430/1134> [21.10.2017.]
19. Bamberger, H. J. (1984). The effect of Logo (Turtle Graphics) on the problem solving strategies used by fourth grade children. Unpublished doctoral dissertation. The University of Maryland, ML.
20. Barquero, B. (1995). La representación de estados mentales en la comprensión de textos desde el enfoque teórico de los modelos mentales. Tesis doctoral (Universidad Autónoma de Madrid: Madrid).
21. Bartlett, F. C. (1932). *Remembering: A Study in Experimental and Social Psychology*. Cambridge University Press. Dostupno na: http://pubman.mpdl.mpg.de/pubman/item/escidoc:2273030:5/component/escidoc:2309291/Bartlett_1932_Remembering.pdf [31.05.2017.]
22. Bayman, P., Mayer, R. E. (1988). Using Conceptual Models to Teach BASIC Computer Programming. *Journal of Educational Psychology*, 80 (3), 291-298.
23. Ben-Ari, M., (2001). Program visualization in theory and practice. *Informatik/Informatique*, 2, 8–11.
24. Benassi, V. A., Overson, C. E., Hakala, C. M. (2014). Applying science of learning in education: Infusing psychological science into the curriculum. Dostupno na: <http://teachpsych.org/ebooks/asle2014/index.php> [18.07.2017.]

25. Bennedsen, J., Caspersen, M. E. (2005). Exposing the Programming Process. In Proceedings of the 36th SIGCSE Technical Symposium on Computer Science Education, 186- 190. Dostupno na: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.92.1080&rep=rep1&type=pdf> [23.10.2017.]
26. Bergin, S., Reilly, R. (2006). Predicting introductory programming performance: A multi-institutional multivariate study. *Computer Science Education*, 16 (4), 303-323.
27. Bétrancourt, M. (2005). The animation and Interactivity Principles in Multimedia Learning. In: Mayer, R. E. (Ed.), *The Cambridge Handbook of Multimedia Learning* (str. 287-296). New York. Cambridge University Press.
28. Bétrancourt, M., Tversky, B. (2000). Effect of computer animation on users' performance: A review. *Le Travail Humain: A Bilingual and Multi-Disciplinary Journal in Human Factors*, Vol. 63, No. 4, 311-329.
29. Bloom, B. S. (Ed.), Engelhart, M. D., Furst, E. J., Hill, W. H., Krathwohl, D. R. (1956). *Taxonomy of educational objectives: The classification of educational goals. Handbook 1: Cognitive domain*. New York: David McKay.
30. Bodemer, D., Ploetzner, R., Feuerlein, I., Spada, H. (2004). The active integration of information during learning with dynamic and interactive visualizations. *Learning and Instruction*, 14 (3), 325–341.
31. Boucheix, J-M., Lowe, R.K. (2010). An eye tracking comparison of external pointing cues and internal continuous cues in learning with complex animations. *Learning and Instruction* 20, 123-135.
32. Boucheix, J-M., Lowe, R.K., Putri, D. K., Groff, J. (2013). Cueing animations: Dynamic signaling aids information extraction and comprehension. *Learning and Instruction*, 25, 71-84.
33. Bruner, J. S. (1961). The act of discovery. *Harvard Educational Review*, 31, 21–32. Dostupno na: <https://digitalauthorshipuri.files.wordpress.com/2015/01/the-act-of-discovery-bruner1.pdf> [18.06.2017.]
34. Byrne, M. D., Catrambone, R., Stasko, J. T. (1999). Evaluating animations as student aids in learning computer algorithms. *Computers & Education*, 33 (4), 253-278.
35. Byrne, P., Lyons, G. (2001). The Effect of Student Attributes on Success in Programming. *Proceedings of 6th Conference on Innovation and Technology in Computer Science Education, ACM SIGCSE Bulletin*, 33 (3), 49-52.

36. Carroll, J. B. (1993). Human cognitive abilities: A survey of factoranalytic studies. Cambridge, England: Cambridge University Press.
37. Caspersen, M. E. (2007). Educating Novices in The Skills of Programming. Doctoral Thesis. Department of Computer Science, University of Aarhus, Denmark. Dostupno na: <http://www.cs.au.dk/~mec/dissertation/Dissertation.pdf> [20.10.2017.]
38. Chandler, P. (2004). The crucial role of cognitive processes in the design of dynamic Visualizations. *Learning and Instruction* 14, 353-357.
39. Chandler, P., Sweller, J. (1991). Cognitive load theory and the format of instruction. *Cognition and Instruction*, 8 (4), 293-332.
40. Chandler, P., Sweller, J. (1992). The split-attention effect as a factor in the design of instruction. *British Journal of Educational Psychology*, 62, 233-246.
41. Clark, J. M., Paivio, A. (1991). Dual Coding Theory and Education. *Educational Psychology Review*, 3 (3), 149-210.
42. Clear, T., Whalley, J., Robbins, P., Philpott, A., Eckerdal, A., Laakso, M., Lister, R. (2011). Report on the final BRACElet workshop. *Journal of Applied Computing and Information Technology*, 15(1). Dostupno na: http://www.citrenz.ac.nz/jacit/JACIT1501/2011Clear_BRACElet.html [31.05.2017.]
43. Clements, D. H. (1986). Effects of Logo and CAI Environments on Cognition and Creativity. *Journal of Educational Psychology* 1986, 78 (4), 309-318.
44. Clements, D. H. (1987). Longitudinal study of the effects of Logo programming on cognitive abilities and achievement. *Journal of Educational Computing Research*. 1 (1), 73-94.
45. Clements, D. H. (1990). Metacomponential Development in a Logo Programming Environment. *Journal of Educational Psychology*, 82 (1), 141-149.
46. Clements, D. H., Battista, M. T. (1990). The effects of logo on children's conceptualizations of angle and polygons. *Journal for Research in Mathematics Education*, 21 (5), 356-371.
47. Clements, D. H., Gullo, D. F. (1984). Effects of Computer Programming on Young Children's Cognition. *Journal of Educational Psychology*, 76 (6), 1051-1058.
48. Clements, D. H., Meredith, J. S. (1992). Research on Logo: Effects and Efficacy. *Journal of Computing in Childhood Education*, 4 (3-4).
49. Corney, M., Fitzgerald, S., Hanks, B., Lister, R., McCauley, R., Murphy, L. (2014). Explain in plain English' questions revisited: Data structures problems. In SIGCSE '14

- Proceedings of the 45th ACM technical symposium on Computer science education, 591-596.
50. Craig, S. D., Gholson, B., Driscoll, D. M. (2002). Animated pedagogical agents in multimedia educational environments: Effects of agent properties, picture features, and redundancy. *Journal of Educational Psychology*, 94, 428–434.
 51. Craik, K. (1943). *The Nature of Explanation*. Cambridge University Press.
 52. de Koning, B. B., Tabbers, H. K., Rikers, R. M. J. P., Paas, F. (2009). Towards a Framework for Attention Cueing in Instructional Animations: Guidelines for Research and Design. *Educational Psychology Review*, 21, 113-140.
 53. de Koning, B. B., Tabbers, H. K., Rikers, R. M. J. P., Paas, F. (2011). Attention cueing in an instructional animation: The role of presentation speed. *Computers in Human Behavior* 27 (1), 41-45.
 54. de Koning, B. B., Tabbers, H. K., Rikers, R. M. J. P., Pass, F. (2007). Attention Cueing as a Means to Enhance Learning from an Animation. *Applied Cognitive Psychology*, 21, 731-746.
 55. Dehnadi, S., Bornat, R., (2006). *The Camel has Two Humps*, Middlesex, University Working Paper. Dostupno na:
<http://www.eis.mdx.ac.uk/research/PhDArea/saeed/paper1.pdf> [27.10.2017.]
 56. Delclos, V., Littlefield, J., Bransford, J. D. (1985). Teaching thinking through LOGO: The importance of method. *Roeper Review: A Journal on Gifted Education*, 7 (3), 153-156.
 57. DeLeeuw, K. E., Mayer, R. E. (2008). A Comparison of Three Measures of Cognitive Load: Evidence for Separable Measures of Intrinsic, Extraneous, and Germane Load. *Journal of Educational Psychology*, 100 (1), 223–234.
 58. Détienne, F. (1990). Expert Programming Knowledge: A Schema-based Approach. Published in J-M Hoc, T.R.G. Green, R. Samurçay, & D. Gilmore (Eds): *Psychology of Programming*. Academic Press, People and Computer Series, 206-222.
 59. Dreyfus, H., Dreyfus, S. (1986). *Mind over machine: The power of human intuition and expertise in the era of the computer*. New York: Free Press.
 60. Driscoll, M. P. (2005). *Psychology of learning for instruction* (3rd Edition). Boston: Pearson.
 61. du Boulay, B., O'Shea, T., Monk, J. (1999). The black box inside the glass box. *International Journal of Man-Machine Studies*, 51 (2), 265-277.

62. Duchastel, P., Waller, R. (1979). Pictorial illustration in instructional texts. *Educational Technology*, 20–25.
63. Emihovich, C., Miller, G. E., Clare, V. (1985). Learning Logo: The Social Context of Cognition. Paper presented at a symposium, "Ethnographic Perspectives on Locating Learning across the Curriculum, the 1985 Annual Meeting of the American Educational Research Association, Chicago.
64. Faraday, P., Sutcliffe, A. (1997a). An Empirical study of Attending and Comprehending Multimedia Presentations. In *Proceedings of the fourth ACM international conference on Multimedia*, 265-275. New York, NY: ACM Press.
65. Faraday, P., Sutcliffe, A. (1997b). Designing Effective Multimedia Presentations. In *Proceedings of the ACM Conference on Human factors in computing systems, CHI' 97*, 272-278. New York, NY: ACM Press.
66. Fay, A. L., Mayer, R. E. (1987). Children's Naive Conceptions and Confusions About Logo Graphics Commands. *Journal of Educational Psychology*, 79 (3), 254-268.
67. Fay, A. L., Mayer, R. E. (1988). Learning Logo: A cognitive analysis. In R. E. Mayer (Ed.), *Teaching and learning computer programming: Multiple researcher perspectives* (55-74). Hillsdale, NJ: Lawrence Erlbaum Associates, Inc.
68. Fay, A. L., Mayer, R. E. (1994). Benefits of Teaching Design Skills Before Teaching Logo Computer Programming: Evidence for Syntax-Independent Learning. *Journal of Educational Computing Research*, 11 (3), 187-210.
69. Feurzeig, W. (2010). Toward a Culture of Creativity: a Personal Perspective on Logo's Early Years and Ongoing Potential. *International Journal of Computers for Mathematical Learning*, 15 (3), 257-265.
70. Feurzeig, W., Papert, S., Bloom, M., Grant, R., Solomon, C. (1969). *Programming-Languages As A Conceptual Framework For Teaching Mathematics. Final Report On The First Fifteen Months Of The LOGO Project. Report No. 1889.* Bolt Beranek And Newman, Inc., Cambridge, Mass. National Science Foundation, Washington, D.C. Dostupno na: <http://files.eric.ed.gov/fulltext/ED038034.pdf> [18.06.2017.]
71. Fletcher, J. D., Tobias, S. (2005). The multimedia principle. In R. E. Mayer (Ed.), *The Cambridge handbook of multimedia learning* (117–134). New York: Cambridge University Press.
72. Fouh, E., Akbar, M., Shaffer, C. A. (2012). The Role of Visualization in Computer Science Education. *Computers in the Schools*, 29 (1/2), 95-117.

73. Gentner, D., Stevens A. (1983). *Mental Models*. Hillsdale NJ: Lawrence Erlbaum Associates.
74. Gillespie, C. W. (2004). Seymour Papert's Vision for Early Childhood Education? A Descriptive Study of Head Start and Kindergarten Students in Discovery-based, Logo-rich Classrooms. *ECRP*, 6 (1). Dostupno na: <http://ecrp.uiuc.edu/v6n1/gillespie.html> [18.06.2017.]
75. Ginns, P. (2006). Integrating information: A meta-analysis of the spatial contiguity and temporal contiguity effects. *Learning and Instruction*, 16, 511-525.
76. Gomes, A., Mendes, A. J. (2007). Learning to program - difficulties and solutions. International Conference on Engineering Education – ICEE, Coimbra, Portugal. Dostupno na: <http://icee2007.dei.uc.pt/proceedings/papers/411.pdf> [20.10.2017.]
77. Greca, I. M., Moreira, M. A. (2000). Mental models, conceptual models, and modelling. *International Journal of Science Education*, 22 (1), 1-11.
78. Guan, Y.-H. (2002). The effects of multimedia presentations on information processing: eye movement analyses of text and picture integration in a multimedia based learning scenario. Doctoral Thesis. Faculty of Linguistics and Literature, University of Bielefeld, Bielefeld. Dostupno na: <http://webdoc.gwdg.de/ebook/h-k/2003/uni-bielefeld/disshabi/2003/0015.pdf> [01.10.2017.]
79. Guan, Y.-H. (2009). A Study on the Learning Efficiency of Multimedia-Presented, Computer-Based Science Information. *Educational Technology & Society*, 12 (1), 62–72.
80. Hansen, S. R. (1999). A framework for animation-embedded hypermedia visualization of algorithms. Doctoral Dissertation, Department of Computer Science & Software Engineering, Auburn University, Auburn, AL, USA.
81. Harel, I., Papert, S. (1991). *Constructionism*. Norwood, New Jersey: Ablex Publishing Corporation. Dostupno na: http://web.media.mit.edu/~calla/web_comunidad/Reading-En/situating_constructionism.pdf [18.06.2017.]
82. Harp, S. E., Mayer, R. E. (1997). The role of interest in learning from scientific text and illustrations: On the distinction between emotional interest and cognitive interest. *Journal of Educational Psychology*, 89, 92-102.
83. Harp, S. E., Mayer, R. E. (1998). How seductive details do their damage: A theory of cognitive interest in science learning. *Journal of Educational Psychology*, 90 (3), 414-434.

84. Harskamp, E., Mayer, R. E., Suhre, C., Jansma, J. (2007). Does the modality principle for multimedia learning apply to science classrooms? *Learning and Instruction*, 18, 465–477.
85. Hegarty, M. (1992). Mental animation: Inferring motion from static displays of mechanical systems. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 18 (5), 1084-1102.
86. Hegarty, M. (2004). Dynamic Visualizations and learning: getting to the difficult questions. *Learning and Instruction* 14, 343-351.
87. Hegarty, M., Just, M. A. (1993). Constructing Mental Models of Machines from Text and Diagrams. *Journal of Memory and Language*, 32 (6), 717-742.
88. Hegarty, M., Kozhevnikov, M. (1999). Spatial abilities, working memory, and mechanical reasoning. In J. Gero & B. Tversky (Eds.), *Visual and Spatial Reasoning in Design*. Sydney, Australia: Key Centre of Design and Cognition.
89. Hegarty, M., Kriz, S., Cate, C. (2003). The Roles of Mental Animations and External Animations in Understanding Mechanical Systems. *Cognition and Instruction*, 21 (4), 325-360.
90. Hegarty, M., Narayanan, N. H., Freitas, P. (2002). Understanding machines from multimedia and hypermedia presentations. In J. Otero, A. Leon, A. C. Graesser (Eds.), *The psychology of science text comprehension*. NJ: Lawrence Erlbaum Associates, 357-384.
91. Hegarty, M., Sims, V. K. (1994). Individual differences in mental animation during mechanical reasoning. *Memory & Cognition*, 22 (4), 411-430.
92. Heidig, S., Müller, J., Reichelt, M. (2015). Emotional design in multimedia learning: Differentiation on relevant design features and their effects on emotions and learning. *Computers in Human Behavior* 44, 81–95.
93. Hoc, J.-M., Green, T. R. G., Samurçay, R., Gilmore, D. J. (Eds) (1990). *Psychology of Programming*, Published by the European Association of Cognitive Ergonomics and Academic Press. Dostupno na: <http://www.cl.cam.ac.uk/teaching/1011/R201/> [12.07.2017.]
94. Höffler, T. N., Leutner, D. (2007). Instructional animation versus static pictures: A meta-analysis. *Learning and instruction* 17, 722-738.
95. Holland, J. H., Holyoak, K. J., Nisbett, R. E., Thagard, P. R. (1986). *Induction: processes of inference, learning, and discovery*. MIT Press, Cambridge, Massachusetts, USA.

96. Hundhausen, C. D., Brown, J. L. (2007). What You See Is What You Code: A “live” algorithm development and visualization environment for novice learners. *Journal of Visual Languages & Computing*, 18 (1), 22-47.
97. Jamet, E., Le Bohec, O. (2007). The effect of redundant text in multimedia instruction. *Contemporary Educational Psychology*, 32, 588–598.
98. Jenkins, C. W. (2012). Microworlds: Building Powerful Ideals in the Secondary School. *US-China Education Review A* 9, 796-803.
99. Jeung, H. J., Chandler, P., Sweller, J. (1997). The role of visual indicators in dual sensory mode instruction. *Educational Psychology*, 17 (3), 329-343.
100. Johnson, C. I., Mayer, R. E. (2012). An Eye Movement Analysis of the Spatial Contiguity Effect in Multimedia Learning. *Journal of Experimental Psychology*, 18 (2), 178–191.
101. Johnson-Laird, P. N. (1980). The history of mental models. In book: *Psychology of reasoning: theoretical and historical perspectives*, Edition: 1st Edition, Publisher: Psychology Press, Editors: Manktelow, Ken I. and Chung, ManCheung, 179-212.
102. Johnson-Laird, P. N. (1983). *Mental Models – Towards a Cognitive Science of Language, Inference and Consciousness*. Cambridge, MA: Harvard University Press.
103. Jonassen, D. H. (1995). Operationalizing mental models: strategies for assessing mental models to support meaningful learning and design-supportive learning environments. *CSCCL '95 The first international conference on Computer support for collaborative learning*, 182-186.
104. Jones, N. A., Ross, H., Lynam, T., Perez, P., Leitch, A. (2011). Mental models: an interdisciplinary synthesis of theory and methods. *Ecology and Society*, 16 (1), 46-46.
105. Kaczmarczyk, L. C., Petrick, E. R., East, J. P., Herman, G. L. (2010). Identifying Student Misconceptions of Programming. *Proceedings of the 41st ACM Technical Symposium on Computer Science Education, SIGCSE '10*, 107-111.
106. Kalyuga, S. (2005). Prior knowledge principle in multimedia learning. In R. E. Mayer (Ed.), *The Cambridge handbook of multimedia learning* (325–338). New York: Cambridge University Press.
107. Kalyuga, S., Chandler, P., Sweller, J. (1998). Levels of expertise and instructional design. *Human Factors*, 40, 1–17.
108. Kalyuga, S., Chandler, P., Sweller, J. (1999). Managing split-attention and redundancy in multimedia instruction. *Applied Cognitive Psychology*, 13, 351–371.

- 109.Kalyuga, S., Chandler, P., Sweller, J. (2000). Incorporating learner experience into the design of multimedia instruction. *Journal of Educational Psychology*, 92, 126–136.
- 110.Kassim, H. (2011). The Impact of Using a Multimedia Learning Tool on Mechanical Engineering Students' Creativity. Doctoral Thesis. Faculty of Education La Trobe University. Dostupno na:
<http://arrow.latrobe.edu.au:8080/vital/access/manager/Repository/latrobe:34112>
[17.10.2017.]
- 111.Kasurinen, J., Purmonen, M., Nikula, U. (2008). A Study of Visualization in Introductory Programming. PPIG, Lancaster.
- 112.Kehoe, C., Stasko, J., Taylor, A. (2001). Rethinking the evaluation of algorithm animations as learning aids: an observational study. *International Journal of Human-Computer Studies*, 54 (2), 265-284.
- 113.Kieren, T. E. (1984). LOGO in Education: What, How, Where, Why and Consequences. Alberta Dept. of Education, Edmonton. Planning Services Branch. Dostupno na:
<https://archive.org/details/logoineducationw00kier> [18.06.2017.]
- 114.Kintsch, W. (1980). Learning from text, levels of comprehension, or: Why anyone would read a story anyway. *Poetics*, 9, 87-98.
- 115.Kinzer, C. K., Littlefield, J., Delclos, V. R., Bransford, J. D. (1984). Different Logo Learning Environments and Mastery: Relationships between Engagement and Learning. *Computers in the Schools*, 2 (2-3), 33-43.
- 116.Klahr, D., Carver, S. M. (1988). Cognitive Objectives in a LOGO Debugging Curriculum: Instruction, Learning, and Transfer. *Cognitive Psychology*, 20, 362-404.
- 117.Kniewald, I. (2005). Terrapin Logo. SysPrint d.o.o, Zagreb.
- 118.Krathwohl, D. R. (2002). A Revision of Bloom's Taxonomy: An Overview. *Theory Into Practice*, 41 (4), 212-218. Dostupno na:
<https://www.depauw.edu/files/resources/krathwohl.pdf> [03.11.2017.]
- 119.Kriz, S., Hegarty, M. (2007). Top-down and bottom-up influences on learning from animations. *International Journal of Human-Computer Studies*, 65 (11), 911-930.
- 120.Kurland, D. M., Pea, R. D. (1985). Children's mental models of recursive Logo programs. *Journal of Educational Computing Research*, 1 (2), 235–243.
- 121.Lahtinen, E., Järvinen, H.-M., Melakoski-Vistbacka, S. (2007). Targeting Program Visualizations. Proceedings of the 12th annual SIGCSE conference on Innovation and technology in computer science education (ITiCSE'07), 39 (3), 256-260.

122. Leahy, W., Chandler, P., Sweller, J. (2003). When auditory presentations should and should not be a component of multimedia instruction. *Applied Cognitive Psychology*, 17 (4), 401–418.
123. Lee, M. O. C. (1991). Guided instruction with Logo programming and the development of cognitive monitoring strategies among college students. *Retrospective Theses and Dissertations*. Paper 9545.
124. Lehrer, R., Guckenberg, T., Lee, O. (1988). Comparative study of the cognitive consequences of inquiry-based logo instruction. *Journal of educational psychology*, 80 (4), 543-553.
125. Lehrer, R., Guckenberg, T., Sancilio, L. (1988). Influences of LOGO on children's intellectual development. In R. E. Mayer (Ed.), *Teaching and learning computer programming* (75–110). Hillsdale, NJ: Erlbaum.
126. Lehrer, R., Lee, M., Jeong, A. (1999). Reflective Teaching of Logo. *The Journal of the Learning Sciences*, 8 (2), 245-289.
127. Lehrer, R., Littlefield, J. (1991). Misconceptions and Errors in LOGO: The Role of Instruction, *Journal of Educational Psychology*, 83 (1), 124-133.
128. Lehrer, R., Littlefield, J. (1993). Relationships among Cognitive Components in Logo Learning and Transfer. *Journal of Educational Psychology*, 85 (2), 317-330.
129. Leppink, J., Paas, F., Van der Vleuten, C. P. M., Van Gog, T., Van Merriënboer, J. J. G. (2013). Development of an instrument for measuring different types of cognitive load. *Behavior Research Methods*, 45 (4), 1058–1072
130. Leutner, D. (2014). Motivation and emotion as mediators in multimedia learning. *Learning and Instruction* 29, 174-175.
131. Levie, W. H., Lentz, R. (1982). Effects of text illustrations: A review of research. *Educational Communication and Technology Journal*, 30 (4), 195–232.
132. Levin, J. R. (1981). On the functions of pictures in prose. In F. J. Pirozzolo, M. C. Wittrock (Eds.), *Neuropsychological and cognitive processes in reading* (203–228). New York: Academic Press.
133. Levin, J. R., Mayer, R. E. (1993). Understanding illustrations in text. In Britton, B. K., Woodward, A., Brinkley, M. (eds.), *Learning from Textbooks*, Erlbaum, Hillsdale, New Jersey, 95–113.
134. Liew, T. W., Tan, S. M. (2016). The Effects of Positive and Negative Mood on Cognition and Motivation in Multimedia Learning Environment. *Educational Technology & Society*, 19 (2), 104–115.

- 135.Lin, L., Atkinson, R. K. (2011). Using animations and visual cueing to support learning of scientific concepts and processes. *Computer & Education*, 56, 650-658.
- 136.Lister, R., Fidge, C., Teague, D. (2009). Further evidence of a relationship between explaining, tracing and writing skills in introductory programming, *Proceeding ITiCSE '09 Proceedings of the 14th annual ACM SIGCSE conference on Innovation and technology in computer science education*, 161-165.
- 137.Lister, R., Simon, B., Thompson, E., Whalley, J. L., Prasad, C. (2006). Not Seeing the Forest for the Trees: Novice Programmers and the SOLO Taxonomy. *ITiCSE '06Proceedings of the 11th annual SIGCSE conference on Innovation and technology in computer science education*, 118-122.
- 138.Littlefield, J., Delclos, V. R., Lever, S., Clayton, K. N., Bransford, J. D., Franks, J. J. (1988). Learning LOGO: Method of teaching, transfer of general skills, and attitudes toward school and computers. In R. E. Mayer (Ed.), *Teaching and learning computer programming* (111–136). Hillsdale, NJ: Erlbaum.
- 139.Lopez, M., Whalley, J., Robbins, P., Lister, R. (2008). Relationships between reading, tracing and writing skills in introductory programming. *Proceeding ICER '08 Proceedings of the Fourth international Workshop on Computing Education Research*, 101-112.
- 140.Lorch, R. F. (1989). Text signaling devices and their effects on reading and memory processes. *Educational Psychology Review*, 1 (3), 209–234.
- 141.Lowe, R. K. (2003). Animation and learning: selective processing of information in dynamic graphics. *Learning and Instruction* 13, 157-176.
- 142.Lowe, R. K. (2004). Interrogation of a dynamic visualization during learning. *Learning and Instruction* 14, 257-274.
- 143.Lowe, R. K. (2005). Multimedia learning of meteorology. In: Mayer, R. E. (Ed.), *The Cambridge Handbook of Multimedia Learning* (str. 429-446). New York. Cambridge University Press.
- 144.Lusk, M. M., Atkinson, R. K. (2007). Animated pedagogical agents: Does their degree of embodiment impact learning from static or animated worked examples? *Applied Cognitive Psychology*, 21, 747–764.
- 145.Ma, L. (2007). Investigating and Improving Novice Programmers' Mental Models of Programming Concepts. Doctoral Thesis. University of Strathclyde, Department of Computer & Information Sciences. Dostupno na:

- <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.721.8479&rep=rep1&type=pdf> [01.10.2017.]
146. Ma, Y., Hung, W-C. (2007). The effect of animation in the design of instructional messages. Selected Papers on the Practice of Educational Communications and Technology Presented at the 2007 Annual Convention of the Association for Educational Communications and Technology, Vol. 2, 265-273.
147. Markman, A. B., Gentner, D. (2001). Thinking. Annual Review of Psychology, 52, 223–247. Dostupno na: <http://cognitrn.psych.indiana.edu/rgoldsto/courses/concepts/markmanthinking.pdf> [31.10.2017.]
148. Markučič, Z., Perić, S., Budin, L., Brođanac, P. (2012). Suvremeniji pristup poučavanju programiranja – rješavanje problema programiranjem nasuprot upoznavanja programskog jezika. MIPRO. Dostupno na: http://mipro-proceedings.com/sites/mipro-proceedings.com/files/upload/ce/ce_074.pdf [03.11.2017.]
149. Martin, F., Mikhak, B., Resnick, M., Silverman, B., Berg, B. (2000). To Mindstorms and beyond: Evolution of a construction kit for magical machines. Robots for kids: Exploring new technologies for learning. San Francisco; London: Morgan Kaufmann.
150. Massa, L. J., Mayer, R. E. (2006). Testing the ATI hypothesis: Should multimedia instruction accommodate verbalizer-visualizer cognitive style? Learning and Individual Differences, 16, 321–335.
151. Matthíasdóttir, Á. (2006). How to Teach Programming Languages to Novice Students? Lecturing or Not? International Conference on Computer Systems and Technologies, 13, 1-6. Dostupno na: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.544.1059&rep=rep1&type=pdf> [21.10.2017.]
152. Mautone, P. D., Mayer, R. E. (2001). Signaling as a Cognitive Guide in Multimedia Learning. Journal of Educational Psychology, 93 (2), 377-389.
153. Mautone, P. D., Mayer, R. E. (2007). Cognitive aids for guiding graph comprehension. Journal of Educational Psychology, 99 (3), 640-652.
154. Mayer, R. E. (1981). The Psychology of How Novices Learn Computer Programming. Journal ACM Computing Surveys (CSUR), 13 (1), 121-141. Dostupno na: <http://files.team2648.com/LearnableProgramming/p121-mayer.pdf> [18.06.2017.]
155. Mayer, R. E. (1989a). Models of Understanding. Review of Educational Research, 59 (1), 43-64.

- 156.Mayer, R. E. (1989b). Systematic Thinking Fostered by Illustrations in Scientific Text. *Journal of Educational Psychology*, 81 (2), 240-246.
- 157.Mayer, R. E. (1992a). *Thinking, Problem Solving and Cognition* (2nd Edition). New York: Freeman.
- 158.Mayer, R. E. (1992b). Teaching for transfer of problem-solving skills to computer programming. In E. DeCorte, M. C. Linn, H. Mandl, & L. Verschaffel (Eds.), *Computer-based learning environments and problem solving* (193-206). New York: Springer-Verlag.
- 159.Mayer, R. E. (1993). Illustrations that instruct. In Glaser, R. (ed.), *Advances in Instructional Psychology*, Vol. 4, Erlbaum, Hillsdale, NJ, pp. 253–284.
- 160.Mayer, R. E. (1996). Learning strategies for making sense out of expository text: The SOI model for guiding three cognitive processes in knowledge construction. *Educational Psychology Review*, 8 (4), 357-371.
- 161.Mayer, R. E. (1997). Multimedia Learning: Are We Asking the Right Questions? *Educational Psychologist*, 32 (1), 1-19.
- 162.Mayer, R. E. (2001). *Multimedia learning*. New York: Cambridge University Press.
- 163.Mayer, R. E. (2003). The promise of multimedia learning: using the same instructional design methods across different media. *Learning and Instruction*, 13 (2), 125–139.
- 164.Mayer, R. E. (2004). Should There Be a Three-Strikes Rule Against Pure Discovery Learning? The Case for Guided Methods of Instruction. *American Psychologist*, 59 (1), 14-19.
- 165.Mayer, R. E. (2005). *The Cambridge Handbook of Multimedia Learning*. New York. Cambridge University Press.
- 166.Mayer, R. E. (2008). Applying the science of learning: Evidence-based principles for the design of multimedia instruction. *American Psychologist*, 63 (8), 760-769.
- 167.Mayer, R. E. (2009). *Multimedia Learning* (2nd Edition). Cambridge: Cambridge University Press.
- 168.Mayer, R. E. (2011). *Applying the science of learning*. Upper Saddle River, NJ: Pearson.
- 169.Mayer, R. E. (2014a). *The Cambridge Handbook of Multimedia Learning*. New York. Cambridge University Press, 2nd Edition.
- 170.Mayer, R. E. (2014b). Incorporating motivation into multimedia learning. *Learning and Instruction*, 29, 171-173.

171. Mayer, R. E. (2014c). Research-Based Principles for Designing Multimedia Instruction. In V. A. Benassi, C. E. Overson, C. M. Hakala (Eds.). *Applying science of learning in education: Infusing psychological science into the curriculum*.
172. Mayer, R. E., Alexander, P. A. (2011). *Handbook of Research on Learning and Instruction*. Routledge: New York. Dostupno na:
173. Mayer, R. E., Anderson, R. B. (1991). Animations need narrations: An experimental test of a dual-coding hypothesis. *Journal of Educational Psychology*, 83 (4), 484-490.
174. Mayer, R. E., Anderson, R. B. (1992). The instructive animation: Helping students build connections between words and pictures in multimedia learning. *Journal of Educational Psychology*, 84 (4), 444-452.
175. Mayer, R. E., Bove, W., Bryman, A., Mars, R., Tapangco, L. (1996). When Less Is More: Meaningful Learning From Visual and Verbal Summaries of Science Textbook Lessons. *Journal of Educational Psychology*, 88 (1), 64-73.
176. Mayer, R. E., Chandler, P. (2001). When Learning Is Just a Click Away: Does Simple User Interaction Foster Deeper Understanding of Multimedia Messages? *Journal of Educational Psychology*, Vol. 93, No. 2, 390-397.
177. Mayer, R. E., Estrella, G. (2014). Benefits of emotional design in multimedia instruction. *Learning and Instruction*, 33, 12-18.
178. Mayer, R. E., Fay, A. L. (1987). A Chain of Cognitive Changes With Learning to Program in Logo. *Journal of Educational Psychology*, 79 (3), 269-279.
179. Mayer, R. E., Fiorella, L. (2014). Principles for reducing extraneous processing in multimedia learning: Coherence, signaling, redundancy, spatial contiguity, and temporal contiguity principles. In R. E. Mayer (Ed.), *The Cambridge handbook of multimedia learning* (2nd Edition, 279-315). New York: Cambridge University Press.
180. Mayer, R. E., Gallini, J. K. (1990). When Is an Illustration Worth Ten Thousand Words? *Journal of Educational Psychology*, 82 (4), 715-726.
181. Mayer, R. E., Griffith, E., Jurkowitz, I. T. N., Rothman, D. (2008). Increased interestingness of extraneous details in multimedia science presentation leads to decreased learning. *Journal of Experimental Psychology*, 14, 329-339.
182. Mayer, R. E., Hegarty, M., Mayer, S., Campbell, J. (2005). When Static Media Promote Active Learning: Annotated Illustrations Versus Narrated Animations in Multimedia Instruction. *Journal of Experimental Psychology*, Vol. 11, No. 4, 256-265.

- 183.Mayer, R. E., Heiser, H., Lonn, S. (2001). Cognitive constraints on multimedia learning: When presenting more material results in less understanding. *Journal of Educational Psychology*, 93, 187–198.
- 184.Mayer, R. E., Johnson, C. I. (2008). Revising the redundancy principle in multimedia learning. *Journal of Educational Psychology*, 100 (2), 380–386.
- 185.Mayer, R. E., Mathias, A., Wetzell, K. (2002). Fostering Understanding of Multimedia Messages Through Pre-Training: Evidence for a Two-Stage Theory Of Mental Model Construction. *Journal of Experimental Psychology*, 8 (3), 147-154.
- 186.Mayer, R. E., Moreno, R. (1998). A Split-Attention Effect in Multimedia Learning: Evidence for Dual Processing Systems in Working Memory. *Journal of Educational Psychology*, 90 (2), 312-320.
- 187.Mayer, R. E., Moreno, R. (2002). Animation as an Aid to Multimedia Learning. *Educational Psychology Review*, Vol. 14, No. 1.
- 188.Mayer, R. E., Moreno, R. (2003). Nine Ways to Reduce Cognitive Load in Multimedia Learning. *Educational Psychologist*, 38 (1), 43–52.
- 189.Mayer, R. E., Moreno, R., Boire, M., Vagge, S. (1999). Maximizing constructivist learning from multimedia communications by minimizing cognitive load. *Journal of Educational Psychology*, 91, 638–643.
- 190.Mayer, R. E., Pilegard, C. (2014). Principles for managing essential processing in multimedia learning: Segmenting, pre-training, and modality principles. In R. E. Mayer (Ed.), *The Cambridge handbook of multimedia learning*. New York: Cambridge University Press.
- 191.Mayer, R. E., Sims, V. K. (1994). For Whom Is a Picture Worth a Thousand Words? Extensions of a Dual-Coding Theory of Multimedia Learning. *Journal of Educational Psychology*, 86 (3), 389-401.
- 192.Mayer, R. E., Steinhoff, K., Bower, G., Mars, R. (1995). A generative theory of textbook design: Using annotated illustrations to foster meaningful learning of science text. *Educational Technology Research and Development*, 43, 31–43.
- 193.Meyer, B. J. F. (1975). *The organization of prose and its effects on memory*. New York: Elsevier.
- 194.Meyer, K., Rasch, T., Schnotz, W. (2010). Effects of animation's speed of presentation on perceptual processing and learning. *Learning and Instruction*, Vol. 20, No. 2, 136-145.

195. Miller, G. A. (1956). The magical number seven, plus or minus two: Some limits on our capacity for processing information. *The Psychological Review*, 63 (2), 81-97.
196. Minsky, M. (1974). *A Framework for Representing Knowledge*. Massachusetts Institute of Technology, A. I. Laboratory, Memo No. 306. Reprinted in *The Psychology of Computer Vision*, P. Winston (Ed.), McGraw-Hill, 1975. Shorter versions in J. Haugeland, Ed., *Mind Design*, MIT Press, 1981, and in *Cognitive Science*, Collins, Allan and Edward E. Smith (Eds.) Morgan-Kaufmann, 1992. Dostupno na: <https://dspace.mit.edu/handle/1721.1/6089> [31.05.2017.]
197. Missiuna, C., Hunter, J., Kemp, T., Hyslop, I. (1987). Development and evaluation of the "thinking with Logo curriculum". Technical Report No. 143. Edmonton, Alberta. Dostupno na: <http://files.eric.ed.gov/fulltext/ED287453.pdf> [30.09.2017.]
198. Miyake, A., Shah, P. (1999). *Models of Working Memory: Mechanisms of Active Maintenance and Executive Control*. New York: Cambridge University Press.
199. Moreno, R., Mayer, R. E. (1999). Cognitive Principles of Multimedia Learning: The Role of Modality and Contiguity. *Journal of Educational Psychology*, 91 (2), 358-368.
200. Moreno, R., Mayer, R. E. (2000). Coherence Effect in Multimedia Learning: The Case for Minimizing Irrelevant Sounds in the Design of Multimedia Instructional Messages. *Journal of Educational Psychology*, 92 (1), 117-125.
201. Moreno, R., Mayer, R. E. (2002a). Learning science in virtual reality multimedia environments: Role of methods and media. *Journal of Educational Psychology*, 94 (3), 598–610.
202. Moreno, R., Mayer, R. E. (2002b). Verbal redundancy in multimedia learning: When reading helps listening. *Journal of Educational Psychology*, 94 (1), 156–163.
203. Moreno, R., Mayer, R. E., Spires, H. A., Lester, J. C. (2001). The case for social agency in computer-based teaching: Do students learn more deeply when they interact with animated pedagogical agents? *Cognition and Instruction*, 19 (2), 177–213.
204. Moreno, R., Ortegado-Layne, L. (2008). Using cases as thinking tools in teacher education: The role of presentation format. *Educational Technology Research and Development*, 56, 449–465.
205. Moreno, R., Valdez, A. (2007). Immediate and Delayed Effects of Using a Classroom Case Exemplar in Teacher Education: The Role of Presentation Format. *Journal of Educational Psychology*, 99 (1), 194–206.

206. Mousavi, S. Y., Low, R., Sweller, J. (1995). Reducing cognitive load by mixing auditory and visual presentation modes. *Journal of Educational Psychology*, 87, 319–334.
207. Myller, M., Bednarik, R. (2006). Methodologies for Studies of Program Visualization. In *Proceedings of the Methods, Materials and Tools for Programming Education Conference (MMT)*, 37-42. Dostupno na: http://www.codewitz.net/papers/MMT_37-42_FullPaper_Myller_Bednarik.pdf [21.10.2017.]
208. MZOŠ (2006). Nastavni plan i program za osnovnu školu. Ministarstvo znanosti, obrazovanja i športa. GIPA, Zagreb. Dostupno na: http://www.azoo.hr/images/AZOO/Ravnatelj/RM/Nastavni_plan_i_program_za_osnovnu_skolu_-_MZOS_2006_.pdf [22.08.2017.]
209. Naps, T. L., Rößling, G., Almstrum, V., Dann, W., Fleischer, R., Hundhausen, C., Korhonen, A., Malmi, L., McNally, M., Rodger, S., Velázquez-Iturbide, J. Á. (2002). Exploring the Role of Visualization and Engagement in Computer Science Education. *ITiCSE-WGR '02 Working group reports from ITiCSE on Innovation and technology in computer science education*, 131-152. Dostupno na: <https://www.cs.duke.edu/csed/rodger/papers/wgReport02.pdf> [21.10.2017.]
210. Narayanan, N. H., Hegarty, M. (2002). Multimedia design for communication of dynamic information. *International Journal of Human-Computer Studies – Special Issue: Interactive graphical communication*, 57 (4), 279-315.
211. Nastasi, B. K., Clements, D. H., Battista, M. T. (1990). Social-Cognitive Interactions, Motivation, and Cognitive Growth in Logo Programming and CAI Problem-Solving Environments. *Journal of Educational Psychology*, 82 (1), 150-158.
212. Ng, H. K. (2014). The use of tracing to reduce transience in instructional animations: a cognitive load theory perspective. Doctoral Thesis, Faculty of Arts and Social Sciences, Univeristy of New South Wales.
213. Norman, D. A. (1983). Some observations on mental models. In D. Gentner & A. L. Stevens (Eds.), *Mental Models*, Hillsdale, NJ: Lawrence Erlbaum Associates Inc.
214. Noss, R., Hoyles, C. (1996). *Windows on Mathematical Meanings: Learning Cultures and Computers* (Dordrecht: Kluwer).
215. O'Neil, H. F., Mayer, R. E., Herl, H. E., Niemi, C., Olin, K., Thurman, R. A. (2000). Instructional strategies for virtual aviation training environments. In H. F. O'Neil, & D. H. Andrews (Eds.), *Aircrew training and assessment* (105–130). Mahwah, NJ: Erlbaum.

- 216.Olive, J. (1991). Logo programming and geometric understanding: an in-depth study. Journal for Research in Mathematics Education, 22 (2), 90-111.
- 217.Ormerod, T. (1990). Human Cognition and Programming. Published in J-M Hoc, T.R.G. Green, R. Samurçay, & D. Gilmore (Eds): Psychology of Programming. Academic Press, People and Computer Series, 63-82.
- 218.Osman, W. I., Elmusharaf, M. M. (2014). Effectiveness of combining algorithm and program Animation: A case study with data structure course. Issues in Informing Science and Information Technology, 11, 155-168. Dostupno na: <http://iisit.org/Vol11/IISITv11p155-168Osman0478.pdf> [20.10.2017.]
- 219.Ozcelik, E., Arslan-Ari, I., Cagiltay, K. (2010). Why does signaling enhance multimedia learning? Evidence from eye movements. Computers in Human Behavior, 26 (1), 110-117.
- 220.Paas, F. (1992). Training strategies for attaining transfer of problem solving skills in statistics: A cognitive load approach. Journal of Educational Psychology, 84 (4), 429–434.
- 221.Paas, F., Renkl, A., Sweller, J. (2003). Cognitive Load Theory and Instructional Design: Recent Developments. Educational Psychologist, 38 (1), 1–4.
- 222.Paget, J. (1952). The origins of intelligence in children. New York, International Universities Press. Dostupno na: http://www.pitt.edu/~strauss/origins_r.pdf [17.10.2017.]
- 223.Pair, C. (1990). Programming, Programming Languages and Programming Methods. Published in J-M Hoc, T.R.G. Green, R. Samurçay, & D. Gilmore (Eds): Psychology of Programming. Academic Press, People and Computer Series, 9-19.
- 224.Paivio, A. (1986). Mental representations: A dual coding approach. New York. Oxford University Press.
- 225.Paivio, A. (1990). Mental representations: A dual-coding approach. New York: Oxford University Press, 2nd Edition.
- 226.Papert, S. (1984). New Theories for New learning's. Paper presented at the National Association of School Psychologists' Conference. Dostupno na: <http://www.stager.org/articles/newlearnings.pdf> [18.06.2017.]
- 227.Papert, S. (1993). Mindstorms: children, computers and powerful ideas. Basic Books, New York.

- 228.Papert, S. (2005). Teaching Children Thinking. Association for the Advancement of Computing in Education (AACE). Contemporary Issues in Technology and Teacher Education, 5 (3), 353-365.
- 229.Papert, S., Watt. D., diSessa, A., Weir, S. (1979). The Brookline LOGO Project. Final Report Part II: Project Summary and Dana Analysis. A. I. Memo No. 545. LOGO Memo No. 53. Massachusetts Inst. of Tech., Cambridge. Artificial Intelligence Lab.
- 230.Park, B., Flowerday, T., Brünken, R. (2015). Cognitive and affective effects of seductive details in multimedia learning. Computers in Human Behavior, 44, 267-278.
- 231.Park, B., Plass, J. L., Brünken, R. (2014). Cognitive and affective processes in multimedia learning. Learning and Instruction 29, 125-127.
- 232.Park, O., Hopkins, R. (1993). Instructional conditions for using dynamic visual displays: a review. Instructional Science 21, 427-449.
- 233.Pashler, H., McDaniel, M., Rohrer, D., Bjork, R. (2008). Learning styles: Concepts and evidence. Psychological Science in the Public Interest, 9, 105–119.
- 234.Pea, R. D. (1983). Logo Programming and Problem Solving. Technical Report No. 12. Symposium of the American Educational Research Association, „Chameleon In The Classroom: Developing Roles Of Computers“, Montreal, Canada.
- 235.Pea, R., Kurland. D. M. (1984). Logo Programming and the Development of Planning Skills. Technical Report No. 16. Dostupno na: <http://files.eric.ed.gov/fulltext/ED249930.pdf> [29.09.2017.]
- 236.Pennington, N., Grabowski, B. (1990). The Tasks of Programming. Published in J-M Hoc, T.R.G. Green, R. Samurçay, & D. Gilmore (Eds): Psychology of Programming. Academic Press, People and Computer Series, 45-62.
- 237.Plass, J. L., Heidig, S., Hayward, E. O., Homer, B. D., Um, E. (2014). Emotional design in multimedia learning: Effects of shape and color on affect and learning. Learning and Instruction, 29, 128-140.
- 238.Putnam, R., Sleeman, D., Baxter, J., Kuspa, L. (1984). A Summary of Misconceptions of High School Basic Programmers. Journal of Educational Computing Research, 2 (4), 459-472. Dostupno na: <http://files.eric.ed.gov/fulltext/ED258556.pdf> [23.10.2017.]
- 239.Rahmat, M., Shahrani, S., Latih, R., Yatim, N. F. M., Zainal, F. A. Z., Ab Rahman, R. (2012). Major problems in basic programming that influence student performance. Procedia - Social and Behavioral Sciences 59, 287 – 296.

- 240.Rapp, D. N. (2005). Mental Models: Theoretical Issues for Visualizations in Science Education. In: Gilbert J.K. (Ed.), Visualization in Science Education (43-60). The Netherlands: Springer.
- 241.Resnick, M. (1993). Behaviour construction kits. Communications of the ACM, 36 (7).
- 242.Rey, G. D. (2012). A review and a meta-analysis of the seductive detail effect. Educational Research Review, 7, 216-237.
- 243.Rias, R. M., Zaman, H. B. (2013). Understanding the role of prior knowledge in a multimedia learning application. Australasian Journal of Educational Technology, 29 (4), 537-548. Dostupno na: <https://ajet.org.au/index.php/AJET/article/view/419/609> [01.11.2017.]
- 244.Rieber, L. P. (1990a). Using Computer Animated Graphics in Science Instruction with Children. Journal of Educational Psychology, 82 (1), 135-140.
- 245.Rieber, L. P. (1990b). Animation in computer-based instruction. Educational Technology Research and Development, 38 (1), 77-86.
- 246.Rieber, L. P. (1991). Animation, incidental learning, and continuing education. Journal of Educational Psychology, 83 (3), 318-328.
- 247.Robins, A., Rountree, J., Rountree, N. (2003). Learning and Teaching Programming: A Review and Discussion. Computer Science Education, 13 (2), 137-172. Dostupno na: <http://home.cc.gatech.edu/csed/uploads/2/robins03.pdf> [20.10.2017.]
- 248.Rosenthal, R. (1991). Meta-analytic procedures for social research. Newbury Park, CA: Sage Publications.
- 249.Roy, M. C. (2000). Comprehension and learning through multimedia: integrative processing of text and illustrations. Doctoral Thesis. Department of Educational and Counselling Psychology, McGill University, Montréal. Dostupno na: http://digitool.library.mcgill.ca/R/?func=dbin-jump-full&object_id=37826&local_base=GEN01-MCG02 [17.07.2017.]
- 250.Rumelhart, D.E. (1980). Schemata: The Building Blocks of Cognition. In R.J. Spiro, B.C. Bruce, W.F. Brewer (Eds.), Theoretical Issues in Reading Comprehension, 33-58. Hillsdale: Lawrence Erlbaum.
- 251.Schank, R. C., Abelson, R. P. (1977). Scripts, Plans, Goals, and Understanding. Hillsdale, NJ: Lawrence Erlbaum Associates.
- 252.Scheiter, K., Eitel, A. (2010). The Effects of Signals on Learning from Text and Diagrams: How Looking at Diagrams Earlier and More Frequently Improves

- Understanding. In: Goel A. K., Jamnik M., Narayanan N. H. (eds). Diagrammatic Representation and Inference, LNAI 6170, 264-270.
253. Schmidt-Weigand, F. (2005). Dynamic visualizations in multimedia learning: The influence of verbal explanations on visual attention, cognitive load and learning outcome. Doctoral Dissertation. Justus-Liebig-Universität Gießen, Institut für Psychologie.
254. Schnotz, W. (1993). Introduction. *Learning and Instruction*, 3, 151-155.
255. Schnotz, W. (2005). An Integrated Model of Text and Picture Comprehension. In R. E. Mayer (Ed.), *The Cambridge Handbook of Multimedia Learning* (1st Edition, 49-69). New York. Cambridge University Press.
256. Schnotz, W. (2014). Integrated Model of Text and Picture Comprehension. In R. E. Mayer (Ed.), *Cambridge Handbook of Multimedia Learning* (2nd Edition, 72-103). Cambridge: Cambridge University Press. Dostupno na:
<https://pdfs.semanticscholar.org/2e0a/a957bc66e50566d37cc59c36064578d1499e.pdf?ga=2.237620608.102733728.1498644637-2085264658.1496154155> [17.10.2017.]
257. Schnotz, W., Lowe, R. K. (2003). External and internal representations in multimedia learning. *Learning and instructions*, 13, 117-123.
258. Schnotz, W., Lowe, R. K. (2008). A unified view of learning from animated and static graphics. In: Lowe, R. K., Schnotz, W. (Eds.), *Learning with animation: Research implications for design*. New York: Cambridge University Press, 304-356.
259. Schnotz, W., Rasch, T. (2005). Enabling, Facilitating, and Inhibiting Effects of Animations in Multimedia Learning: Why Redcution of Cognitive Load Can Have Negative Results on Learning. *Educational Technology Research and Development*, Vol. 53, No. 3, 47-58.
260. Schwamb, K. B. (1990). Mental Models: A Survey. Dostupno na:
<https://pdfs.semanticscholar.org/be2b/6abd67f28c56c1a72bd3c5dbdad4be3d1832.pdf> [31.10.2017.]
261. Shehane, R., Sherman, S. (2014). Visual teaching model for introducing programming languages. *Journal of Instructional Pedagogy*, 14. Dostupno na:
<http://www.aabri.com/manuscripts/141823.pdf> [21.10.2017.]
262. Shneiderman, B., Mayer, R. (1979). Syntactic/Semantic Interactions in Programmer Behavior: A Model and Experimental Results. *International Journal of Computer and Information Sciences*, 8 (3), 219-238.

- 263.Simon (2011). Assignment and Sequence: Why Some Students Can't Recognize a Simple Swap. Proceedings of the 11th Koli Calling International Conference on Computing Education Research, Koli Callin '11, 17-20.
- 264.Solaz-Portolés, J. J., Sanjosé-López, V. (2009). Working Memory in Science Problem Solving: A Review Of Research. *Revista Mexicana de Psicología*, 26 (1), 79-90.
- 265.Soloway, E., Ehrlich, K. (1984). Empirical Studies of Programming Knowledge. *Journal IEEE Transactions on Software Engineering*, Vol. 10, 5, 595-609.
- 266.Sorva, J. (2012). Visual Program Simulation in Introductory Programming Education. Doctoral Dissertation 61. Aalto University, School of Science, Department of Computer Science and Engineering.
- 267.Staggers, N., Norcio, A. F. (1993). Mental Models: concepts for human-computer interaction research. *Int. J. Man-Machine Studies*, 38, 587-605.
- 268.Stiller, K. D. (2007). The Modality Principle in Multimedia Learning An Open Question: When Speech Fails to Foster Learning? In *Open innovation. Neue Perspektiven im Kontext von Information und Wissen*, 129-144.
- 269.Sutherland, R. (1993). Connecting Theory and Practice: Results from the Teaching of Logo. *Educational Studies in Mathematics*, 24 (1), Design of Teaching, 95-113.
- 270.Sweller, J. (1994). Cognitive load theory, learning difficulty, and instructional design. *Learning and Instruction*, 4, 293-312.
- 271.Sweller, J. (1999). Instructional design in technical areas. Camberwell, Australia: ACER Press.
- 272.Sweller, J., Ayres, P. L., Kalyuga, S., Chandler, P. (2003). The expertise reversal effect. *Educational Psychologist*, 38 (1), 23-31.
- 273.Sweller, J., Chandler, P. (1994). Why Some Material Is Difficult to Learn. *Cognition and Instruction*, 12 (3), 185-233.
- 274.Sweller, J., van Merriënboer, J. J. G., Paas, F. G. W. C. (1998). Cognitive architecture and instructional design. *Educational Psychology Review*, 10 (3), 251-296.
- 275.Szlávi, P., Zsakó, L. (2003). Methods of teaching programming. In: *Teaching Mathematics and Computer Science*, 1 (2), 247–257.
- 276.Tabbers, H., Martens, R., van Merriënboer, J. J. G. (2004). Multimedia instructions and cognitive load theory: Effects of modality and cueing. *British Journal of Educational Psychology*, 74, 71-81.

277. Tekdal, M. (2013). The Effect of an Example-Based Dynamic Program Visualization Environment on Students' Programming Skills. *Educational Technology & Society*, 16 (3), 400–410.
278. Tindall-Ford, S. K., Chandler, P., Sweller, J. (1997). When Two Sensory Modes are Better Than One. *Journal of Experimental Psychology*, 3 (4), 257-287.
279. Tsang, C. (2004). Constructivist Learning Using Simulation and Programming Environments. *MIE2002H Readings in Industrial Engineering I*.
280. Turner, J. M., Bélanger, F. P. (1996). Escaping from Babel: Improving the Terminology of Mental Models in the Literature of Human-Computer Interaction. *Canadian Journal of Information and Library Science*, 21 (3/4), 35-58.
281. Tversky, B. (1993). Cognitive maps, cognitive collages, and spatial mental models. In A. U. Frank and I. Campari (Eds.), *Spatial information theory: A theoretical basis for GIS* (14-24). Berlin: Springer-Verlag.
282. Tversky, B., Heiser, J., Lozano, S., Mackenzie, R., Morrison, J. (2008). Enriching animations. In book R. K. Lowe & W. Schnotz (Eds.), *Learning with animation: Research implications for design* (263-285). New York: Cambridge University Press.
283. Tversky, B., Morrison, J. B., Bétrancourt, M. (2002). Animation: Can it facilitate? *International Journal of Human-Computer Studies*, 57, 247-262.
284. van Gog, T., Kirschner, F., Kester, L., Paas, F. (2012). Timing and Frequency of Mental Effort Measurement: Evidence in Favor of Repeated Measures. *Applied Cognitive Psychology, Special Issue: New Directions and Challenges to Cognitive Load Theory*, 26 (6), 833-839.
285. van Merriënboer, J. J. G., Sweller, J. (2005). Cognitive load theory and complex learning: Recent developments and future directions. *Educational Psychology Review*, 17, 147-177.
286. Varga-Papp, Z., Szlávi, P., Zsakó, L. (2008). ICT teaching methods – Programming languages. *Annales Mathematicae et Informaticae*, 35, 163-172.
287. Venables, A., Tan, G., Lister, R. (2009). A Closer Look at Tracing, Explaining and Code Writing Skills in The Novice Programmer. *ICER '09 Proceedings of the fifth international workshop on Computing education research workshop*, 117-128.
288. Wilson, R. A., Keil, F. C. (1999). *The MIT encyclopedia of the cognitive sciences*. Cambridge: The MIT Press. Dostupno na:

<http://www.aiai.ed.ac.uk/project/oplan/documents/1999/1999-MITECS.pdf>

[01.10.2017.]

289. Winslow, L. E. (1996). Programming pedagogy – A psychological overview. SIGCSE Bulletin, 28, 17–22.
290. Wittrock, M. C. (1974). Learning as a generative activity. Educational Psychologist, 19 (2), 87-95.
291. Wittrock, M. C. (1989). Generative processes of comprehension. Educational Psychologist, 24 (4), 345-376.
292. Wong, A., Marcus, N., Ayres, P., Smith, L., Cooper, G. A., Sweller, J. (2009). Instructional Animations can be Superior to Statics when Learning Human Motor Skills. Computers in Human Behavior, 25, 339-347.
293. Yue, C. L., Ligon Bjork, E., Bjork, R. A. (2013). Reducing Verbal Redundancy in Multimedia Learning: An Undesired Desirable Difficulty? Journal of Educational Psychology, 105 (2), 266–277.

8 POPIS SLIKA

| | |
|---|----|
| Slika 1. Model kognitivne teorije multimedijuskog usvajanja znanja. Izvor: Mayer, R. E. (2005, str. 37, 2014a, str. 52)..... | 23 |
| Slika 2. Kognitivni procesi – „odabir relevantnih riječi iz prikazanog teksta ili govora“ i odabir „relevantnih slika iz prikazanih ilustracija“..... | 27 |
| Slika 3. Kognitivni procesi – „organiziranje odabranih riječi ili dijelova zvučne predodžbe u verbalni mentalni model“, „organiziranje odabranih slika ili dijelova vizualne predodžbe u slikovni mentalni model“ i „povezivanje svih dijelova predodžbi s predznanjem“ | 29 |
| Slika 4. Primjer multimedijske poruke za obradu slike (grafički pokazivač u liku kornjače i geometrijski lik trokut), govora (opis osnovnih naredbi programskog kôda) i pisane riječi (prikaz programskog kôda)..... | 42 |
| Slika 5. Obrada slike prema KTMUZ. Izvor: Mayer, R. E. (2005, str. 43; 2014a, str. 52) | 43 |
| Slika 6. Obrada govorene riječi prema KTMUZ. Izvor: Mayer, R. E. (2005, str. 43) | 44 |
| Slika 7. Obrada pisane riječi prema KTMUZ. Izvor: Mayer, R. E. (2005, str. 43) | 45 |
| Slika 8. Model dvostrukog kodiranja multimedijuskog usvajanja znanja prilagođen prema teoriji dvostrukog kodiranja (Paivio, A, 1986, prema Mayer, R. E., 2005; Clark, J. M. i Paivio, A., 1991). Broj 1 odnosi se na izgradnju predstavničkih verbalnih veza; broj 2 odnosi se na izgradnju predstavničkih vizualnih veza; broj 3 odnosi se na izgradnju referentnih veza; broj 4 odnosi se na dohvaćanje informacija iz dugoročne memorije. Izvor: Mayer, R. E. i Sims, V. K. (1994), str. 390. ... | 53 |
| Slika 9. Uvodni slajd „Naslovna“ MIPL-a za prvu cjelinu (kontrolna i eksperimentalna skupina)..... | 82 |
| Slika 10. Razvoj MIPL-a..... | 83 |
| Slika 11. Prvi slajd „Kornjača“ (slika lijevo) i drugi slajd „Logo Naredbe“ (slika desno) MIPL-a za prvu cjelinu (kontrolna i eksperimentalna skupina) | 84 |
| Slika 12. Treći slajd „FD_BK Naredbe“ MIPL-a za prvu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno)..... | 85 |
| Slika 13. Četvrti slajd „RT_LT Naredbe“ MIPL-a za prvu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno) | 87 |
| Slika 14. Peti slajd „PU_PD_PE Naredbe“ MIPL-a za prvu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno) | 89 |
| Slika 15. Šesti slajd „Crtanje Kvadrata“ MIPL- za prvu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno)..... | 90 |
| Slika 16. Sedmi slajd „Crtanje Trokuta“ MIPL-a za prvu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno)..... | 92 |
| Slika 17. Osmi slajd „Crtanje Šesterokuta“ MIPL-a za prvu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno) | 94 |

| | |
|---|-----|
| Slika 18. Deveti slajd „Repeat Petlja“ MIPL-a za prvu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno) | 96 |
| Slika 19. Deseti slajd „Niz Likova“ MIPL-a za prvu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno) | 98 |
| Slika 20. Uvodni slajd „Naslovna“ (slika lijevo) i prvi slajd „Procedura“ (slika desno) MIPL-a za drugu cjelinu (kontrolna i eksperimentalna skupina) | 100 |
| Slika 21. Drugi slajd „Jedna Ulazna Vrijednost“ MIPL-a za drugu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno) | 101 |
| Slika 22. Treći slajd „Dvije Ulazne Vrijednosti“ (prvi dio) MIPL-a za drugu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno) | 103 |
| Slika 23. Treći slajd „Dvije Ulazne Vrijednosti“ (drugi dio) MIPL-a za drugu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno) | 104 |
| Slika 24. Četvrti slajd „Više Ulaznih Vrijednosti“ (prvi dio) MIPL-a za drugu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno) | 106 |
| Slika 25. Četvrti slajd „Više Ulaznih Vrijednosti“ (drugi dio) MIPL-a za drugu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno) | 107 |
| Slika 26. Peti slajd „Višestruke Kornjače“ (prvi dio) MIPL-a za drugu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno) | 109 |
| Slika 27. Peti slajd „Višestruke Kornjače“ (drugi dio) MIPL-a za drugu cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno) | 110 |
| Slika 28. Uvodni slajd „Naslovna“ (slika lijevo) i prvi slajd „Tipovi Podataka“ (slika desno) MIPL-a za treću cjelinu (kontrolna i eksperimentalna skupina) | 112 |
| Slika 29. Drugi slajd „Rijeci & Liste 01“ (slika lijevo) i treći slajd „Riječi & Liste 02“ (slika desno) MIPL-a za treću cjelinu (kontrolna i eksperimentalna skupina) | 113 |
| Slika 30. Četvrti slajd „MAKE naredba“ (slika lijevo) i peti slajd „WHILE petlja“ (prvi dio, slika desno) MIPL-a za treću cjelinu (kontrolna i eksperimentalna skupina) | 114 |
| Slika 31. Peti slajd „WHILE petlja“ (drugi dio) MIPL-a za treću cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno) | 116 |
| Slika 32. Šesti slajd „FOR petlja“ (prvi dio) MIPL-a za treću cjelinu (kontrolna i eksperimentalna skupina) | 118 |
| Slika 33. Šesti slajd „FOR petlja“ (drugi dio) MIPL-a za treću cjelinu – kontrolna skupina (slika lijevo) i eksperimentalna skupina (slika desno) | 119 |
| Slika 34. Sedmi slajd „Algoritmi“ MIPL-a za treću cjelinu – kontrolna skupina | 121 |
| Slika 35. Sedmi slajd „Algoritmi“(prvi i drugi dio) MIPL-a za treću cjelinu – eksperimentalna skupina | 122 |

9 POPIS TABLICA

| | |
|---|-----|
| Tablica 1. Instrukcijska struktura Loga (Kieren, T. E., 1984, str. 5.; Papert, S. 1983, Kniewald, I., 2005)..... | 15 |
| Tablica 2. Temeljni elementi <i>kognitivne teorije multimedijskog usvajanja znanja</i> (Mayer, R. E., 2005, str. 33-36) | 22 |
| Tablica 3. Memorijska struktura prema KTMUZ (Mayer, R. E., 2014, str. 53) | 25 |
| Tablica 4. Tri vrste kognitivnih opterećenja (DeLeeuw, K. E. i Mayer, R. E., 2008; Paas, F., Renkl, A. i Sweller, J., 2003)..... | 38 |
| Tablica 5. Osnovna struktura multimedijskog prikaza za konstrukciju dinamičnog mentalnog modela računalnog algoritma (Narayanan, N. H. i Hegarty, M., 2002, str. 20)..... | 75 |
| Tablica 6. Devet načela KTMUZ-a i načelo raščlanjivanja MKPMR-a korišteni u razvoju MIPL-a... | 79 |
| Tablica 7. Opis faza razvoja MIPL-a | 80 |
| Tablica 8. Analiza načela MIPL-a za prvi i drugi slajd prve nastavne cjeline (kontrolna i eksperimentalna skupina) | 84 |
| Tablica 9. Analiza načela MIPL-a za treći slajd prve nastavne cjeline | 86 |
| Tablica 10. Analiza načela MIPL-a za četvrti slajd prve nastavne cjeline | 87 |
| Tablica 11. Analiza načela MIPL-a za peti slajd prve nastavne cjeline | 89 |
| Tablica 12. Analiza načela MIPL-a za šesti slajd prve nastavne cjeline | 91 |
| Tablica 13. Analiza načela MIPL-a za sedmi slajd prve nastavne cjeline..... | 92 |
| Tablica 14. Analiza načela MIPL-a za osmi slajd prve nastavne cjeline | 94 |
| Tablica 15. Analiza načela MIPL-a za deveti slajd prve nastavne cjeline | 96 |
| Tablica 16. Analiza načela MIPL-a za deseti slajd prve nastavne cjeline..... | 98 |
| Tablica 17. Analiza načela MIPL-a za prvi slajd „Procedura“ druge nastavne cjeline (kontrolna i eksperimentalna skupina) | 100 |
| Tablica 18. Analiza načela MIPL-a za drugi slajd druge nastavne cjeline..... | 102 |
| Tablica 19. Analiza načela MIPL-a za treći slajd druge nastavne cjeline | 104 |
| Tablica 20. Analiza načela MIPL-a za četvrti slajd druge nastavne cjeline | 107 |
| Tablica 21. Analiza načela MIPL-a za peti slajd „Višestruke Kornjače“ (prvi dio) druge nastavne cjeline (kontrolna i eksperimentalna skupina)..... | 109 |
| Tablica 22. Analiza načela MIPL-a za peti slajd (drugi dio) druge nastavne cjeline | 110 |
| Tablica 23. Analiza načela MIPL-a za prvi slajd „Tipovi Podataka“ treće nastavne cjeline (kontrolna i eksperimentalna skupina) | 112 |
| Tablica 24. Analiza načela MIPL-a za drugi i treći slajd treće nastavne cjeline (kontrolna i eksperimentalna skupina) | 113 |
| Tablica 25. Analiza načela MIPL-a za četvrti slajd „MAKE naredba“ treće nastavne cjeline (kontrolna i eksperimentalna skupina) | 114 |

| | |
|--|-----|
| Tablica 26. Analiza načela MIPL-a za peti slajd „WHILE petlja“ (prvi dio) treće nastavne cjeline (kontrolna i eksperimentalna skupina) | 115 |
| Tablica 27. Analiza načela MIPL-a za peti slajd „WHILE petlja“ (drugi dio) treće nastavne cjeline | 116 |
| Tablica 28. Analiza načela MIPL-a za šesti slajd „FOR petlja“ (prvi dio) treće nastavne cjeline (kontrolna i eksperimentalna skupina) | 118 |
| Tablica 29. Analiza načela MIPL-a za šesti slajd „FOR petlja“ (drugi dio) treće nastavne cjeline | 119 |
| Tablica 30. Analiza načela MIPL-a za sedmi slajd „Algoritmi“ treće nastavne cjeline (kontrolna skupina) | 121 |
| Tablica 31. Analiza načela MIPL-a za sedmi slajd „Algoritmi“ (prvi i drugi dio) treće nastavne cjeline (eksperimentalna skupina)..... | 122 |
| Tablica 32. Uzorak | 124 |
| Tablica 33. Plan istraživanja po tjednima..... | 128 |
| Tablica 34. Prikaz strukture eksperimentalne i kontrolne skupine sa stajališta upotrebe programskog jezika na fakultetu..... | 130 |
| Tablica 35. Analiza varijabli predtesta za cjelokupni uzorak ispitanika | 132 |
| Tablica 36. Prikaz statističke značajnosti razlika između eksperimentalne i kontrolne skupine prema varijablama za cjelokupni uzorak ispitanika | 134 |
| Tablica 37. Prikaz rezultata u prvom tjednu istraživanja za obje skupine (eksperimentalna i kontrolna) | 135 |
| Tablica 38. Prikaz ukupnih rezultata eksperimentalne i kontrolne skupine za zadatke zapamćivanja i razumijevanja sadržaja za I. tjedan istraživanja | 138 |
| Tablica 39. Testiranje razlika između eksperimentalne i kontrolne skupine u pogledu zapamćivanja i razumijevanja sadržaja | 140 |
| Tablica 40. Rezultati testiranja razlika po pripadnosti studijskoj godini..... | 141 |
| Tablica 41. Prikaz rezultata u drugom tjednu istraživanja za obje skupine (eksperimentalna i kontrolna) | 142 |
| Tablica 42. Prikaz ukupnih rezultata eksperimentalne i kontrolne skupine za zadatke zapamćivanja i razumijevanja sadržaja za II. tjedan istraživanja | 145 |
| Tablica 43. Testiranje razlika između eksperimentalne i kontrolne skupine u pogledu zapamćivanja i razumijevanja sadržaja | 147 |
| Tablica 44. Rezultati testiranja razlika po pripadnosti studijskoj godini..... | 148 |
| Tablica 45. Prikaz ukupnih rezultata eksperimentalne i kontrolne skupine za zadatke zapamćivanja i razumijevanja sadržaja za I. i II. tjedan istraživanja..... | 150 |
| Tablica 46. Testiranje razlika između eksperimentalne i kontrolne skupine u pogledu zapamćivanja i razumijevanja sadržaja | 152 |
| Tablica 47. Rezultati testiranja razlika po pripadnosti studijskoj godini..... | 153 |

| | |
|--|-----|
| Tablica 48. Prikaz rezultata u trećem tjednu istraživanja za obje skupine (eksperimentalna i kontrolna) | 154 |
| Tablica 49. Prikaz ukupnih rezultata eksperimentalne i kontrolne skupine za zadatke zapamćivanja i razumijevanja sadržaja za III. tjedan istraživanja..... | 157 |
| Tablica 50. Testiranje razlika između eksperimentalne i kontrolne skupine u pogledu zapamćivanja i razumijevanja sadržaja | 161 |
| Tablica 51. Rezultati testiranja razlika po pripadnosti studijskoj godini..... | 162 |
| Tablica 52. Mjerenje mentalnog napora studenata tijekom sva tri tjedna istraživanja (eksperimentalna i kontrolna skupina)..... | 163 |
| Tablica 53. Mjerenje mentalnog napora studenata Mann-Whitneyevim testom..... | 167 |
| Tablica 54. Rezultati za prvo kategorijalno pitanje..... | 168 |
| Tablica 55. Rezultati za drugo kategorijalno pitanje..... | 168 |

10 PRILOG A: PREDTEST

Šifra:

Molimo zaokružite:

Spol: M Ž

Grad u kojem studirate: Zagreb Čakovec

Godina studija: III IV V

Molimo Vas odgovorite na slijedeća pitanja:

1. Koje ste programske jezike učili u osnovnoj i srednjoj školi?

2. Jeste li se koristili kojim programskim jezikom na fakultetu? DA / NE

3. Ako da, u sklopu kojeg kolegija?

4. Jeste li do sada učili ikoji programski jezik u izvannastavnim aktivnostima (tečajevi i sl.)? DA / NE

5. Ako da, napišite koje su to bile aktivnosti.

6. Koji vam se odslušani kolegij na modulu informatike najviše svidio?

7. Procijenite Vaše znanje programiranja općenito? (1 – nimalo; 5 – u potpunosti):

1 2 3 4 5

8. Koliko ste upoznati s osnovnim pojmovima i značajkama Logo jezika?

(1 – nimalo; 5 – u potpunosti):

1 2 3 4 5

9. Procijenite Vaše znanje programiranja u Logo jeziku? (1 – nimalo; 5 – u potpunosti):

1 2 3 4 5

10. Programiranje mi je:

Zanimljivo;

Uopće se ne slažem ♦ Ne slažem se ♦ Nemam mišljenje ♦ Slažem se ♦ Potpuno se slažem

Dosadno;

Uopće se ne slažem ♦ Ne slažem se ♦ Nemam mišljenje ♦ Slažem se ♦ Potpuno se slažem

Korisno;

Uopće se ne slažem ♦ Ne slažem se ♦ Nemam mišljenje ♦ Slažem se ♦ Potpuno se slažem

Teško;

Uopće se ne slažem ♦ Ne slažem se ♦ Nemam mišljenje ♦ Slažem se ♦ Potpuno se slažem

11. Video tutorijali (npr. kratki *youtube* isječci) na Internetu su korisni;

Uopće se ne slažem ♦ Ne slažem se ♦ Nemam mišljenje ♦ Slažem se ♦ Potpuno se slažem

12. Imate li naviku učiti iz video tutorijala na Internetu: DA / NE

13. Na internetu za učenje radije koristim:


- a. Video tutorijal
- b. Tekst i slikovno-tekstualni sadržaj
- c. Kombinacija jednog i drugog
- d. Ništa od toga

11 PRILOG B: ZADATCI ZA PRVI TJEDAN ISTRAŽIVANJA

ŠIFRA:

Datum:

1. Proučite položaje kornjača na slici i u kućice upišite pripadajuće naredbe!



2. Nacrtajte putanju kretanja kornjače prema zadanoj listi naredaba!

```
FD 50 RT 120
FD 100 LT 120
PU FD 50 PD
LT 120
FD 100 RT 120
```

3. Koje naredbe treba zapisati u postojeći programski kôd, kako kornjača pri svom kretanju ne bi ostavila redundantni trag prije iscrtavanja drugog i trećeg trokuta?

```
REPEAT 3 [FD 40 RT 120]
```


```
 FD 40 
```

```
REPEAT 3 [FD 40 RT 120]
```



```
 FD 40 
```

```
REPEAT 3 [FD 40 RT 120]
```

```
 FD 40 
```




4. Proučite sliku i zapišite programski kôd za crtanje pravokutnika!





Koliko puta se u programu za crtanje pravokutnika ponavlja blok naredaba FD 35 RT 90?

Koliko puta se u programu za crtanje pravokutnika ponavlja blok naredaba FD 55 RT 90?

Je li moguće programski kôd za crtanje pravokutnika zapisati pomoću REPEAT petlje?



5. Napišite programski kôd za crtanje lika prikazanog slikom!



12 PRILOG C: ZADATCI ZA DRUGI TJEDAN ISTRAŽIVANJA

ŠIFRA:

Datum:

Napomena: u svim zadacima početno usmjerenje kornjače je 0° .

1. a) Zaokružite sliku koja odgovara izlaznoj vrijednosti procedure *PRO1*!

| | |
|---|--|
| <pre> TO PRO1 FD 40 RT 120 FD 40 RT 120 FD 40 RT 120 END </pre> | |
|---|--|



- b) Zaokružite sliku koja odgovara izlaznoj vrijednosti procedure *PRO2*!

| | |
|--|--|
| <pre> TO PRO2 RT 90 FD 50 LT 30 FD 25 END </pre> | |
|--|--|

2. Nacrtajte izlaznu vrijednost zadane procedure prema sljedećim ulaznim vrijednostima:
 $A = 50$, $B = 20$, $KUT = 30^\circ$. Na crtežu označite vrijednosti unutarnjih kutova i duljine stranica!

| | |
|---|-------------------------------------|
| <pre> TO PARALELOGRAMA B KUT LT 90 RT 180-KUT FD B RT KUT FD A RT 180-KUT FD B RT KUT FD A RT 90 END </pre> | <p>Početni položaj kornjače</p> |
|---|-------------------------------------|

3. Napišite proceduru pod nazivom *GEOLIK* za crtanje šesterokuta s jednom ulaznom vrijednosti A (vrijednost duljine stranice)!



4. Proučite programski kôd i u prazne kućice upišite odgovarajući broj kornjače!

TO CRTAJ

SETTURTLES 4

TELL [0 1 2 3]


ASK 0 [RT 60 FD 50]

ASK 1 [LT 60 FD 50]

ASK 2 [FD 30]


ASK 3 [BK 50]

END




5. Koristeći se procedurom za crtanje paralelograma nadopunite programski kôd za crtanje kocke duljine stranice 50 px, uz pomoć višestrukih kornjača, koristeći SETTURTLES, TELL i ASK naredbe!

Poziv procedure:
PARALELOGRAM A B 90



Poziv procedure:
PARALELOGRAM A B 45




SETTURTLES



TELL []

ASK 0 [PARALELOGRAM 50 50 90]

ASK 1 [PARALELOGRAM 50 50 45]



Početni položaj
svih kornjača

13 PRILOG D: ZADATCI ZA TREĆI TJEDAN ISTRAŽIVANJA

ŠIFRA:

Datum:

1. U prazna polja upišite rezultat izvođenja sljedećih naredbi:

| | |
|----------------------|--|
| ITEM 4 "AUSTRALIJA = | |
| BL [78 IT 03] = | |
| ITEM 3 [L E T 1] = | |
| PR "VIOLINA = | |
| LAST [MIR 007] = | |
| FIRST "DRVO = | |
| COUNT "JEZERO = | |
| BF "MJESEC = | |
| COUNT [1 2 1 RT] = | |

2. U prazna polja upišite vrijednosti varijabli nakon izvođenja MAKE naredbi!

| | |
|---------------------|--------|
| MAKE "VAR1 7 | VAR1 = |
| MAKE "VAR2 "LJETO | VAR2 = |
| MAKE "VAR3 [PET 05] | VAR3 = |

3. Proučite sljedeći programski kôd. Što će biti ispisano naredbom *PR A* za stanje varijable $X = 4$?

```
MAKE "A 0
```

```
MAKE "X 2
```

```
WHILE [X < 7] [(PR A) (MAKE "A A+2) (MAKE "X X+2)]
```

4. Proučite sljedeći programski kôd i ispišite rezultat izvođenja *FOR* petlje!

```
MAKE "N "VATRA
```

```
FOR "K 1 (COUNT N) [PR K]
```

5. Proučite sljedeći programski kôd. Što će biti ispisano naredbom *PR N* za stanje varijable $K = 4$?

```
MAKE "N "VATROMET
```

```
FOR "K 1 8 [(PR N) (MAKE "N BF(N))]
```

6. Proučite zadanu proceduru i u prazna polja upišite vrijednosti varijabli nakon izvođenja *MAKE* i *PR* naredbi za sljedeće ulazne vrijednosti: $A = 11$, $B = 4$, $C = 7$.

```
TO PROGRAM A B C
```

```
MAKE "BROJ1 A
```

```
MAKE "BROJ2 B
```

```
MAKE "BROJ3 C
```

```
MAKE "OPERACIJA (2*BROJ1) - BROJ2 + (BROJ3)/2
```

```
PR OPERACIJA
```

```
END
```

| | |
|-------------|--|
| BROJ1 = | |
| BROJ2 = | |
| BROJ3 = | |
| OPERACIJA = | |

Što će biti ispisano naredbom *PR OPERACIJA*?

14 PRILOG E: SKALA ZA SUBJEKTIVNU PROCJENU MENTALNOG NAPORA

ŠIFRA:

Datum:

Molimo zaokružiti odgovor koji se odnosi na tebe (1, 2, 3, 4, 5, 6, 7):

Tijekom tutorijala koje je upravo završilo, uložio/uložila sam:

| Premali mentalni napor | | | Osrednji mentalni napor | | | Prejaki mentalni napor |
|------------------------------|---|---|-------------------------------|---|---|------------------------------|
| 1 | 2 | 3 | 4 | 5 | 6 | 7 |

15 PRILOG F: IZLAZNI EVALUACIJSKI UPITNIK

ŠIFRA:

Datum:

Svrha ovom upitniku jest evaluirati multimedijски sadržaj za učenje osnovnih pojmova programskoga jezika Logo, kojima ste se koristili tijekom ovoga istraživanja.

1. Jeste li se do sada susreli s ovakvom vrstom multimedijskog sadržaja za učenje programiranja?

DA.....NE

2. Ocijenite **korisnost** multimedijskog sadržaja, za Vas osobno, na skali od 1 do 5:

nekorisno 1.....2.....3.....4.....5 jako korisno

3. Procijenite **primjerenost** ovakve vrste multimedijskih sadržaja za studente za učenje osnovnih pojmova iz Logo jezika, na skali od 1 do 5:

neprijmjereno 1.....2.....3.....4.....5 potpuno primjereno

4. Koliko su Vas multimedijски sadržaji **motivirali** za učenje Logo jezika?

nimalo 1.....2.....3.....4.....5 u potpunosti

5. Ocijenite **tehničku kvalitetu** multimedijskih sadržaja na skali od 1 (nekvalitetno) do 5 (iznimno kvalitetno):

a) Tekstualno (teorija) 1.....2.....3.....4.....5

b) Vizualno (grafički prikazi) 1.....2.....3.....4.....5

c) Govorno 1.....2.....3.....4.....5

d) Animacijski (ako ih je bilo) 1.....2.....3.....4.....5

6. Procijenite „**virtualnog učitelja**“ (**vođenje**) kroz multimedijске sadržaje za učenje Logo jezika, na skali od 1 do 5:

neuspješno vođenje 1.....2.....3.....4.....5 iznimno uspješno vođenje

7. Uporaba multimedijškog sadržaja za **rješavanje zadataka** za Vas je bila:

nekorisna 1.....2.....3.....4.....5 jako korisna

8. Ocijenite **rad** s multimedijškim sadržajima kroz protekla tri tjedna, ocjenama od 1 do 5:

| | Prvi tjedan | Drugi tjedan | Treći tjedan |
|-----------------|-------------|--------------|--------------|
| Zanimljivi | | | |
| Dosadni | | | |
| Korisni | | | |
| Teško savladivi | | | |

9. Ocijenite Vaše **znanje programiranja** u Logo jeziku:

1.....2.....3.....4.....5

10. Sviđa li Vam se **ovakav način učenja**?

Da.....Neznam.....Ne

Obrazložite zašto:

11. Stekli ste iskustvo učenja na multimedijškom sadržaju. Kako mislite da bi se ovaj program mogao **unaprijediti**?

16 ŽIVOTOPIS

Nataša Rogulja rođena je 10. lipnja godine 1983., u Bjelovaru. Osnovnu i srednju školu završila je u Bjelovaru. Na Fakultetu elektrotehnike i računarstva (FER) Sveučilišta u Zagrebu 2007. godine obranila je diplomski rad na temu *Projektiranje digitalnih filtara čiji su koeficijenti sume potencija broja 2*, s odličnim uspjehom i stekla zvanje diplomiranog inženjera elektrotehnike. 2008. godine radila je kao suradnik i pomoćni asistent u programu obrazovanja na Zavodu za elektroničke sustave i obradbu informacije, FER, Zagreb. Od 2009. do 2015. godine bila je zaposlena kao znanstveni novak na projektu *Informacijsko-komunikacijska kompetencija edukatora* – broj 227-2271694-1166 (voditeljica: prof. dr. sc. Ljubica Bakić-Tomić), na Katedri za informacijske i komunikacijske znanosti Učiteljskog fakulteta Sveučilišta u Zagrebu. Godine 2010. upisuje poslijediplomski doktorski studij na Sveučilištu u Zagrebu, Filozofskog fakulteta, Informacijske i komunikacijske znanosti, gdje 2015. godine brani temu doktorskog rada *Razvoj multimedijske instruktivne poruke za programski jezik Logo*. Tema je odobrena od Senata Sveučilišta u Zagrebu nadnevka 08. prosinca 2015. g. (KLASA: 643-03/15-09/221, URBROJ: 380-130/042-15-2), tj. odlukom Sveučilišta u Zagrebu, Filozofskog fakulteta od 29. listopada 2015. (KLASA: 643-02/15-07/57, UBROJ: 3804-460-15-3). Trenutno je zaposlena u nastavnom zvanju predavača na Učiteljskom fakultetu Sveučilišta u Zagrebu. U suautorstvu objavljuje znanstvene i stručne radove. Sudjeluje na znanstvenim i stručnim skupovima u zemlji i inozemstvu.